



universidad  
de león



# Escuela de Ingenierías Industrial, Informática y Aeroespacial

## MÁSTER EN INGENIERÍA AERONÁUTICA

Trabajo de Fin de Máster

Mantenimiento Predictivo en Motores de Aviación mediante la  
utilización de Metodologías de Aprendizaje Supervisado

Predictive Maintenance for Aircraft Engines based on Supervised  
Learning Methodologies

Autor: Nerea Juan González  
Tutor: Javier Díez González  
Cotutora: Hilde Pérez García

Septiembre, 2022

**UNIVERSIDAD DE LEÓN**  
**Escuela de Ingenierías Industrial, Informática y Aeroespacial**

**MÁSTER EN INGENIERÍA AERONÁUTICA**  
**Trabajo de Fin de Máster**

**ALUMNO:** Nerea Juan González

**TUTOR:** Javier Díez González, Hilde Pérez García

**TÍTULO:** Mantenimiento Predictivo en Motores de Aviación mediante la utilización de Metodologías de Aprendizaje Supervisado

**TITLE:** Predictive Maintenance for Aircraft Engines based on Supervised Learning Methodologies

**CONVOCATORIA:** Septiembre, 2022

**RESUMEN:**

El mantenimiento de motores de aviación es una tarea esencial en el sector aeronáutico, ya que estos suponen una gran inversión para las compañías aéreas. Por ello, es importante la realización de tareas de mantenimiento que aseguren largos ciclos de vida. Además, es fundamental realizar una correcta planificación de este mantenimiento para poder reducir sus costes asociados. En este trabajo se estudiarán las características del mantenimiento correctivo, preventivo y predictivo. Debido a las ventajas que presenta el mantenimiento predictivo, estudiaremos las diferentes metodologías que se utilizan en su implementación, donde el uso de algoritmos de Inteligencia Artificial, más concretamente de Aprendizaje Supervisado, está muy extendido. Por esta razón, se propone la utilización de algoritmos de Regresión Lineal, Random Forest y Redes Neuronales para la predicción del RUL de motores turbofan mediante la base de datos CMAPSS de la NASA. También se ha propuesto la creación de un modelo de la degradación sufrida en los sensores que miden las diferentes instancias de la base de datos. Este modelo se propone como un acercamiento a la realidad, ya que los datos encontrados en la base de datos son simulados. Tras aplicar este modelo se han entrenado los tres algoritmos, mediante el uso de lenguaje Python, y se han comparado las métricas con las obtenidas anteriormente, donde podemos observar que Random Forest proporciona los mejores resultados. Además se propone el estudio de los resultados obtenidos teniendo en cuenta el histórico de datos. Con todo ello se satisfacen los objetivos planteados para este Trabajo de Fin de Máster.

**ABSTRACT:**

The maintenance of aircraft engines is an essential task in the aviation sector, as they represent a large investment for airlines. For this reason, it is important to carry out maintenance tasks that ensure long life cycles. Moreover, it is essential to carry out a correct planning of this maintenance in order to reduce the associated costs. In this work, the characteristics of corrective, preventive and predictive maintenance will be studied. Due to the advantages of predictive maintenance, we will study the different methodologies used in its implementation, where the use of Artificial Intelligence algorithms, more specifically Supervised Learning, is very widespread. For this reason, we propose the use of Linear Regression, Random Forest and Neural Networks algorithms for the prediction of the RUL of turbofan engines using the NASA CMAPSS database. The creation of a model of the degradation suffered by the sensors measuring the different instances of the database has also been proposed. This model is proposed as an approximation to reality, since the data found in the database are simulated. After applying this model, the three algorithms have been trained, using Python language, and the metrics have been compared with those obtained previously, where we can see that Random Forest provides the best results. In addition, a study of the results obtained is proposed, taking into account the historical data. With all this, the objectives set out for this Master's Thesis have been met.

**Palabras clave:** Mantenimiento predictivo, RUL, Aprendizaje Supervisado

**Firma del alumno:**

**VºBº Tutor:**

**VºBº Cotutora:**

## Agradecimientos

En primer lugar, me gustaría agradecer el apoyo de mi familia durante la realización de este Trabajo de Fin de Máster y durante toda esta etapa universitaria. También me gustaría agradecer a mis amigos por todos los momentos de apoyo y ánimo durante esta etapa.

También me gustaría dar las gracias a mi novio Rubén por ser mi apoyo incondicional durante estos 6 años y compañero de vida.

Finalmente, me gustaría agradecer todo el apoyo y ayuda recibida por parte del Área de Mecánica de la Escuela de Ingenierías durante todo el transcurso de este Trabajo de Fin de Máster.

# Índice

	<b>Página</b>
<b>Índice de Figuras</b>	<b>6</b>
<b>Índice de Tablas</b>	<b>8</b>
<b>Listado de Abreviaturas y Acrónimos</b>	<b>9</b>
<b>1. Introducción</b>	<b>11</b>
<b>2. Objetivos</b>	<b>13</b>
2.1. Objetivo general . . . . .	13
2.2. Objetivos específicos . . . . .	13
<b>3. Estado del arte</b>	<b>15</b>
3.1. Mantenimiento en motores de aviación . . . . .	15
3.2. Mantenimiento Correctivo . . . . .	18
3.3. Mantenimiento Preventivo . . . . .	19
3.4. Mantenimiento Predictivo . . . . .	21
3.5. Investigaciones Previas . . . . .	29
<b>4. Metodologías de inteligencia artificial empleadas en PdM</b>	<b>35</b>
4.1. Regresión Lineal . . . . .	39
4.2. Random Forest . . . . .	41
4.3. Artificial Neural Networks . . . . .	44

---

<b>5. Mediciones en Motores de Aviación</b>	<b>49</b>
5.1. Sensores en Motores de Aviación . . . . .	51
5.1.1. Mediciones de Presión . . . . .	52
5.1.2. Mediciones de Temperatura . . . . .	54
5.1.3. Mediciones del flujo de combustible . . . . .	60
5.1.4. Mediciones del flujo másico de aire . . . . .	61
5.1.5. Medición de la velocidad de rotación del eje . . . . .	61
<b>6. Base de datos y Preprocesamiento de los datos para los Algoritmos de PdM</b>	<b>63</b>
6.1. Base de datos CMAPSS . . . . .	64
6.2. Preprocesamiento de los Datos . . . . .	66
6.2.1. Límite Superior RUL . . . . .	66
6.2.2. Normalización . . . . .	68
6.2.3. División de los Datos . . . . .	68
<b>7. Desarrollo de un modelo de Incertidumbre y Deriva de los sensores</b>	<b>71</b>
<b>8. Resultados</b>	<b>76</b>
<b>9. Conclusiones</b>	<b>84</b>
<b>Referencias</b>	<b>87</b>

## Índice de Figuras

3.1. Accidente producido por la rotura de un disco de la turbina de un motor.	16
3.2. Pérdida de prestaciones y eficiencia de un motor como consecuencia de daños en la turbina. . . . .	17
3.3. Curva de la bañera que representa la probabilidad de fallo de una pieza a lo largo de su ciclo de vida . . . . .	19
3.4. Esquema representativo de las tres estrategias de mantenimiento: RM, PM Y PdM . . . . .	22
3.5. Comparación de RM, PM y PdM respecto al coste y la frecuencia de mantenimiento . . . . .	23
3.6. Selección de la estrategia de mantenimiento a seguir en función de los indicadores de fallo y aspectos de seguridad y costes. . . . .	25
3.7. Librería de Fallos. . . . .	26
3.8. Desviación percibida que puede asociarse a una avería en los álabes de la turbina. . . . .	27
3.9. Clasificación de los principales algoritmos de predicción de RUL. . . . .	32
4.1. Esquema representativo de las subdivisiones dentro de la IA . . . . .	36
4.2. Ejemplo del Resultado obtenido mediante Regresión Lineal Simple . . . . .	40
4.3. Árbol de Decisión para la predicción de la clase de un valor dado x . . . . .	42
4.4. Representación de un perceptrón . . . . .	44
4.5. Representación de una neurona con una única entrada . . . . .	45
4.6. Red neuronal de entrada múltiple . . . . .	46
4.7. Representación de una capa de neuronas . . . . .	47
4.8. ANN con dos capas ocultas . . . . .	48

5.1.	Efecto de la no linealidad en la curva de medición de un transductor. . .	53
5.2.	Esquema funcional de un termopar. . . . .	55
5.3.	Cambio en el coeficiente de Seebeck con la Temperatura y cambio de la diferencia de potencial con la temperatura de varios tipos de termopares.	56
5.4.	Esquema del equilibrio térmico producido en un termopar dentro de un motor de aviación. . . . .	57
5.5.	Oxidación de un termopar y su efecto en el coeficiente de Seebeck. . . .	59
5.6.	Uso de una rueda fónica para medir la velocidad de rotación de un eje.	62
6.1.	Base de datos para el entrenamiento de las metodologías de Aprendizaje Supervisado. . . . .	65
6.2.	Comparativa modelo de predicción al aplicar o no un límite al RUL de motores de aviación. . . . .	67
6.3.	Representación gráfica de Overfitting y Underfitting . . . . .	70
7.1.	Evolución del error de un sensor de la base de datos con y sin las modificaciones planteadas. Ambas curvas han sido suavizadas con un filtro para poder apreciar el efecto de la deriva del sensor. . . . .	74
8.1.	Comparativa del RUL real, la estimación del RUL y la estimación del RUL filtrada para un motor de la base de datos. . . . .	79
8.2.	Comparativa del RMSE generado entre las curvas del RUL y del RUL estimado y filtrado por cada motor. La curva azul, indicativa del RUL estimado, tiene un valor promedio de 15.67 ciclos, mientras que la curva naranja, indicativa del RUL suavizado, tiene un promedio inferior, de valor 14.42 ciclos. . . . .	80
8.3.	Esquema del funcionamiento del algoritmo de evaluación para el RUL de un segmento de mediciones. . . . .	81

## Índice de Tablas

3.1. Tabla comparativa de las diferentes estrategias de planificación del mantenimiento. . . . .	29
6.1. Sensores de la base de datos para cada instancia de medición. . . . .	64
7.1. Clasificación de las mediciones de la base de datos CMAPSS y utilización de los valores de incertidumbre para cada tipo de medición, siguiendo los valores asociados a los diferentes sensores más utilizados para cada medición. . . . .	72
7.2. Relación de deriva para los diferentes rangos de exposición de un termopar tipo K. . . . .	73
8.1. Lista de los hiperparámetros ajustados experimentalmente de cada metodología utilizada para los cálculos de esta Sección. . . . .	76
8.2. Resultados de la evaluación del RMSE en la estimación del RUL para cada metodología sobre los datos existentes en cada caso de estudio. Unidades en ciclos del motor. . . . .	77
8.3. Tabla comparativa de la estimación actual del RUL dado un histórico de N mediciones. . . . .	82

## Listado de Abreviaturas y Acrónimos

**ANN** Artificial Neural Network.

**CBM** Condition-Based-Maintenance.

**CD** Discharge Coefficient.

**CFD** Computational Fluid Dynamics.

**CMAPSS** Commercial Modular Aero-Propulsion System Simulation.

**DR** Drift Rate.

**ECU** Electronic Control Unit.

**HPC** High Pressure Compressor.

**HPT** High Pressure Turbine.

**IA** Inteligencia Artificial.

**ML** Machine Learning.

**MSE** Mean Squared Error.

**PdM** Predictive Maintenance o Mantenimiento Predictivo.

**PHM** Prognostics and Health Monitoring.

**PM** Preventive Maintenance o Mantenimiento Predictivo.

**RBT** Resistance Bulbs Thermometers.

**ReLU** Rectified Linear Unit.

**RL** Reinforcement Learning.

**RM** Reactive Maintenance o Mantenimiento Correctivo.

**RMSE** Root Mean Square Error.

**RUL** Remaining Useful Life.

# 1. Introducción

El mantenimiento en el sector aeronáutico juega un papel fundamental debido a la larga vida en servicio de las aeronaves y motores. A medida que avanza el tiempo de operación de cada componente estos van sufriendo desgaste que en el futuro puede llegar a producir un fallo.

En nuestro sector la ocurrencia de estos fallos puede suponer grandes problemas para las compañías aéreas. En el caso de ocurrir un fallo, y por lo tanto la necesidad de realizar tareas de mantenimiento, podría suponer grandes pérdidas para la compañía por retrasos o incluso anulaciones de vuelos por no tener la aeronave disponible para realizar la operación. Además de ello otro aspecto de vital importancia es que estos fallos podrían llegar a comprometer la seguridad de la aeronave, pasajeros y tripulantes que se encuentren en ella.

Cabe destacar que la planificación del mantenimiento tiene el mismo o incluso mayor impacto que la realización propia de las tareas de mantenimiento. El desarrollo de estas tareas de mantenimiento en el momento adecuado tiene un gran impacto en el aspecto económico. Por ello en este Trabajo de Fin de Máster vamos a realizar un estudio de las diferentes estrategias de mantenimiento que se aplican a motores de aviación.

Posteriormente nos centraremos en el Mantenimiento Predictivo debido a las ventajas que ofrece frente a las otras dos estrategias de mantenimiento estudiadas. También haremos una revisión de la literatura sobre las investigaciones y desarrollos realizados en este campo, destacando la importancia de la Inteligencia Artificial en este ámbito.

A continuación, nos centraremos más específicamente en nuestro estudio del problema planteado y para ello haremos una revisión de las metodologías de Aprendizaje Supervisado más utilizadas en la literatura.

Introduciremos la base de datos CMAPSS realizada por la NASA en la que se detallan diferentes características de motores turbofan con sus ciclos de vida restantes antes del fallo. Aplicaremos las metodologías de Aprendizaje Supervisado a esta base de datos y realizaremos una comparativa de las métricas alcanzadas por cada uno de

estos algoritmos.

Otro aspecto a desarrollar es la influencia que tiene la exactitud de las mediciones de cada uno de los tipos de sensores. Debido a que en la base de datos no se tiene en cuenta esta incertidumbre intrínseca en la naturaleza de cada uno de los sensores y tampoco se tiene en cuenta la deriva que se produce debido a las condiciones de operación, se ha planteado un modelo de degradación que tenga en cuenta estos aspectos.

Finalmente, en la Sección 8 se presentan los resultados obtenidos mediante las tres metodologías de Aprendizaje Supervisado. Se describen los diferentes hiperparámetros utilizados en cada una de ellas, así como las métricas obtenidas. Estas métricas se obtendrán para la base de datos original y para la base de datos modificada con la degradación de los sensores, de forma que se pueda realizar la comparativa de los resultados obtenidos. Mediante esta comparativa se realizará la elección del algoritmo que mejor rendimiento tenga para la predicción de vida útil restante, que en nuestro caso será Random Forest. Además, se realizará un estudio del impacto que tiene en las predicciones el histórico de datos de operación del motor.

## 2. Objetivos

En este Trabajo de Fin de Máster se pretende realizar un desarrollo e implementación que cumpla una serie de objetivos tanto generales como específicos.

### 2.1. Objetivo general

- Implementación de metodologías de Aprendizaje Supervisado al mantenimiento predictivo, con el objetivo de predecir la vida útil restante de motores de aviación.

### 2.2. Objetivos específicos

- Estudio de las diferentes técnicas de planificación de mantenimiento que se realizan en motores de aviación. Destacando las características, ventajas y desventajas de cada una de ellas.
- Estudio de investigaciones en la literatura donde se apliquen cada una de las técnicas de mantenimiento.
- Estudio de las técnicas de Aprendizaje Supervisado que posteriormente utilizaremos para el desarrollo de nuestro problema.
- Estudio de los diferentes sensores existentes para realizar la medición de las variables que participan en el ciclo de operación de un turbofan. Destacando la incertidumbre asociada a las medidas tomadas por cada uno de estos sensores así como la deriva producida por las condiciones y tiempo de operación.
- Desarrollo de un modelo de incertidumbre y degradación de los sensores que posteriormente se introducirá a la base de datos CMAPSS, de forma que podríamos modelar características que guarden mayor similitud con la operación real de una aeronave.
- Aplicación de las metodologías de Aprendizaje Supervisado para la predicción de vida útil restante de los motores. Comparativa de los resultados obtenidos por

cada metodología aplicadas a la base de datos CMAPSS con y sin el modelo de degradación.

### 3. Estado del arte

La adquisición de aeronaves supone una gran inversión para las compañías aéreas, como consecuencia, la explotación de estos activos se extiende hasta varias décadas de puesta en servicio [1]. Estos elevados ciclos de vida requieren la aplicación de un mantenimiento que supervise la aeronavegabilidad del avión y todos sus componentes. No obstante, la actividad del mantenimiento no solo repercute en el aspecto de la seguridad de los vuelos, sino que también afecta a la competitividad de la aerolínea.

La planificación de los mantenimientos en el tiempo supone una tarea de gran complejidad. Una planificación demasiado pesimista puede forzar la entrada en taller de aviones en perfectas condiciones mientras que una planificación errática puede desencadenar una avería que resulte en un compromiso de seguridad o en altos costes de recambio de piezas, siendo precisamente la búsqueda de este compromiso lo que diferencia a la industria aeronáutica de otros sectores.

Entre los diversos elementos que componen a una aeronave, los motores que la propulsan constituyen uno de los componentes más susceptible a averías como consecuencia de las extremas condiciones de carga, temperatura y presión que contemplan en su desempeño [2]. El estudio de la planificación del mantenimiento en los motores de aviación es precisamente el punto en el cual se embarca este Trabajo de Fin de Máster.

#### 3.1. Mantenimiento en motores de aviación

La filosofía de diseño aplicada a los sistemas propulsivos de las aeronaves busca reducir el peso del motor al mínimo. La existencia de peso innecesario se traduce en una pérdida de prestaciones para la aeronave, así como un mayor coste de combustible para su operación. Como consecuencia, los elementos que componen los motores de aviación se diseñan para que operen en condiciones próximas a los límites de los materiales que los constituyen. Un ejemplo de esta afirmación es la operación de los álabes de compresor y turbina, las cuales se someten a tensiones radiales que superan el límite elástico de los materiales en aceleraciones extremas [2].

Por tanto, la etapa de diseño, que es en la que se definen los materiales a utilizar en la fabricación del motor, afectará directamente en el posterior mantenimiento que se realizará durante todo su ciclo de vida. En esta etapa también se definen los parámetros del ciclo de funcionamiento del motor y las velocidades de rotación de los componentes que influyen en el desgaste de los componentes [2].

Estas extremas condiciones de operación aceleran la oxidación y fatiga de estos componentes, lo que puede desencadenar una avería con consecuencias potencialmente catastróficas, como es el caso de la Figura 3.1.



**Figura 3.1.** Accidente producido por la rotura de un disco de la turbina de un motor. La energía cinética que contiene este componente en vuelo dificulta su contención y consecuentemente su avería representa un gran riesgo para la seguridad incluso para diseños modernos [2].

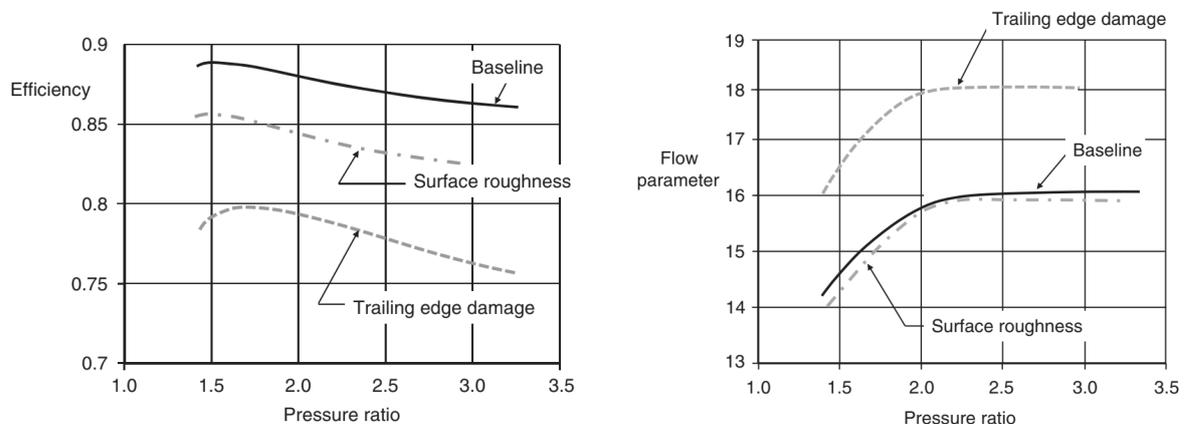
No obstante, esta filosofía de minimización de peso se sostiene sobre múltiples ensayos que garantizan la seguridad y eficiencia de estos componentes dentro de un rango aceptable. Es precisamente la existencia de este rango lo que requiere la realización de tareas de mantenimiento para comprobar el estado de los componentes y valorar su reparación o sustitución.

Sin embargo, comprobar el estado de los componentes en los motores de aviación requiere comúnmente inhabilitar la aeronave para su explotación comercial durante las tareas de mantenimiento, lo cual se traduce en una reducción de la flota activa de la compañía y un aumento de los costes, lo que compromete la competitividad de las aerolíneas [3].

Adicionalmente, las revisiones mayores de los motores de aviación, comúnmente denominadas por su término en inglés: *engine overhauls*, necesarias para el mantenimiento de ciertos componentes encarecen más aún los costes de mantenimiento y añaden incertidumbre al estado del motor ya que requieren el desmontaje y posterior ensamblaje de gran parte de sus componentes pudiendo ocasionar algún desperfecto en alguna pieza que se encontrara en perfecto estado de operación [4].

Por otra parte, el deterioro de ciertos componentes del motor se traduce en una pérdida de eficiencia en su operación, y consecuentemente en una pérdida de prestaciones y aumento de consumo de combustible. En la Figura 3.2 se aprecia la influencia de daños en los componentes del motor que no afectan a la seguridad de la aeronave pero sí a sus prestaciones y a su eficiencia.

Esta pérdida de eficiencia resulta en un incremento del consumo de combustible de los motores, lo que se traduce en pérdidas millonarias cuando escalamos este gasto en todas las horas de operación de los aviones para toda la flota de una aerolínea, además del daño medioambiental ocasionado por este exceso de contaminación [5].



(a) Influencia de daños en la turbina en su eficiencia.

(b) Influencia de daños en la turbina en el gasto del motor.

**Figura 3.2.** Pérdida de prestaciones y eficiencia de un motor como consecuencia de daños en el borde de salida y en la rugosidad superficial de los álabes de la turbina [2].

Consecuentemente, la eficiente planificación del mantenimiento de los motores representa una tarea crucial para el desempeño de las compañías aéreas. Es importante realizar la diferenciación de mantenimiento entendido como aquellas acciones que se realizan para restaurar el funcionamiento óptimo de un motor y la planificación de

estas tareas.

Teniendo en cuenta la primera definición cabe destacar que el mantenimiento comprende tanto las tareas realizadas mientras el motor se encuentra instalado en el ala como las que se realizan en un overhaul [6]. Sin embargo, en este Trabajo de Fin de Máster nos centraremos en el aspecto de la planificación de las tareas de mantenimiento.

Podemos definir el mantenimiento óptimo como aquel que, garantizando la seguridad del motor, repercute en los mínimos costes para la compañía aérea. No obstante, este compromiso resulta difícil de trazar, ya que el ritmo por el cual se degradan los componentes varía en función de su uso, de sus defectos de fabricación, y del estado de componentes adyacentes entre otros, lo que nos dificulta elaborar un modelo exacto que nos indique con alta exactitud cuando hacer las tareas de mantenimiento.

Como consecuencia de esta problemática, surgen tres principales estrategias de planificación de mantenimiento: el mantenimiento correctivo o RM (Reactive Maintenance); el mantenimiento preventivo o PM (Preventive Maintenance) y el mantenimiento predictivo o PdM (Predictive Maintenance). A continuación, analizaremos las particularidades de cada estrategia, comentando las ventajas y desventajas de cada una de ellas a la hora de su implementación en el mantenimiento de motores de aviación.

### 3.2. Mantenimiento Correctivo

El mantenimiento correctivo, también denominado en inglés *run to failure maintenance*, es aquel que se realiza después de que el componente haya sufrido una avería [7]. El RM permite maximizar la utilización de los componentes al llevarlos hasta el límite de sus capacidades [8]. Sin embargo el coste de reparación puede llegar a ser mayor que el beneficio obtenido al llevar los componentes hasta el límite de su vida útil [9].

Por otra parte, cuando los elementos alcanzan el fin de su vida útil, las averías suelen venir precedidas de fenómenos de altas vibraciones, sobrecalentamientos y rozamiento, lo que puede dañar elementos adyacentes al componente averiado, elevando aún más los costes de reparación [10].

Otro aspecto negativo de esta estrategia de mantenimiento es que debido a que

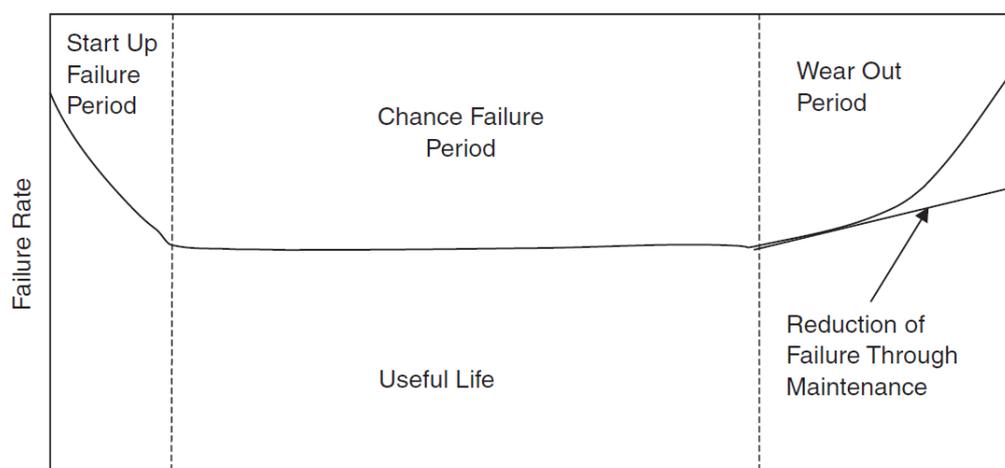
no se sabe cuando va a producirse el fallo es necesario tener un gran almacén con las piezas necesarias para llevar a cabo el mantenimiento cuando sea necesario. En caso contrario, la línea de producción tendrá que parar ocasionando grandes pérdidas [11].

Si bien esta estrategia tiene cierta cabida en la industria bajo ciertas aplicaciones [12], en el sector aeronáutico, su uso es poco común, especialmente en componentes críticos cuya avería pueda incurrir en riesgos para la seguridad operacional de la aeronave.

### 3.3. Mantenimiento Preventivo

El mantenimiento preventivo se caracteriza por seguir una planificación espaciada en el tiempo de las actividades de mantenimiento, a fin de minimizar la probabilidad de fallo de los diversos componentes bajo supervisión [8, 13].

Bajo esta estrategia, cada componente recibe un tiempo de vida útil de forma que, tras su finalización, dicho componente ha de ser reemplazado. Este tiempo de vida útil se estima a raíz de ensayos y de la evolución de la probabilidad de fallo de los componentes a lo largo de su vida útil, la cual sigue la curva de la bañera, mostrada en la Figura 3.3.



**Figura 3.3.** Evolución de la probabilidad de fallo de un componente de un motor de aviación a lo largo de su ciclo de vida. [4].

En la Figura 3.3 se puede observar que al inicio del ciclo de vida de una pieza se

tiene una mayor probabilidad de fallo lo cual es debido principalmente a fallos o grietas que se producen durante los procesos de fabricación y que una vez se pone la pieza en servicio se propagan produciendo el fallo o debido a problemas durante la instalación [9].

A medida que pasa el tiempo la probabilidad de fallo va disminuyendo hasta estabilizarse, esto es el periodo de operación normal de la pieza. Sin embargo la probabilidad de fallo no es nunca nula debido a fallos aleatorios que pueden ocurrir [2].

Posteriormente, la probabilidad de fallo vuelve a crecer debido al desgaste sufrido en servicio y es especialmente en este periodo cuando más importante es el mantenimiento, ya que nos permite poder prolongar el tiempo en servicio de la pieza siempre que pueda garantizar la seguridad durante la operación del motor [4].

El PM ofrece ciertas garantías de que no se produzcan averías inesperadas que ocasionen problemas de seguridad o que incurran en mayores costes de reparación o de inhabilitación de la flota. No obstante, a fin de buscar estas garantías, el cálculo de la vida útil es una estimación pesimista, por lo que es habitual que se sustituyan componentes en un estado aceptable [2].

Esta diferencia se debe a que la vida útil de un componente no solo depende de las horas de servicio, si no de las condiciones de operación, como por ejemplo en el campo de los motores, el número de encendidos del motor o la cantidad de aceleraciones hasta máxima potencia que ha percibido, lo cual dificulta la estimación del tiempo de vida de los componentes [14].

Adicionalmente, el PM requiere la inhabilitación del motor para asistir tareas de mantenimiento de forma frecuente, lo que se traduce en altos costes de mantenimiento y pérdidas por tener parte de la flota inactiva.

En ciertas ocasiones, estos costes exceden a los de sustitución de los componentes, por lo que una política habitual en las compañías aéreas consiste en adelantar estos mantenimientos programados de forma que coincidan con periodos de baja demanda, agrupando además diversas tareas de mantenimiento, lo que implica cambiar un gran número de piezas en buen estado [4].

No obstante, como ya se ha adelantado previamente, la estimación de la vida útil de un componente es una ciencia inexacta aunque se realizan múltiples ensayos para determinar los diferentes modos de fallo y su frecuencia ante diversas condiciones, esto no nos garantiza una completa seguridad ante todo tipo de averías, pudiendo ocasionarse averías inesperadas antes del periodo de mantenimiento previsto [9]. Esto puede apreciarse en la Figura 3.3, en la cual la probabilidad de fallo nunca es nula. En el caso de que esto sucediera se tendría que llevar a cabo el RM con su tiempo de inactividad del motor y costes asociados [9].

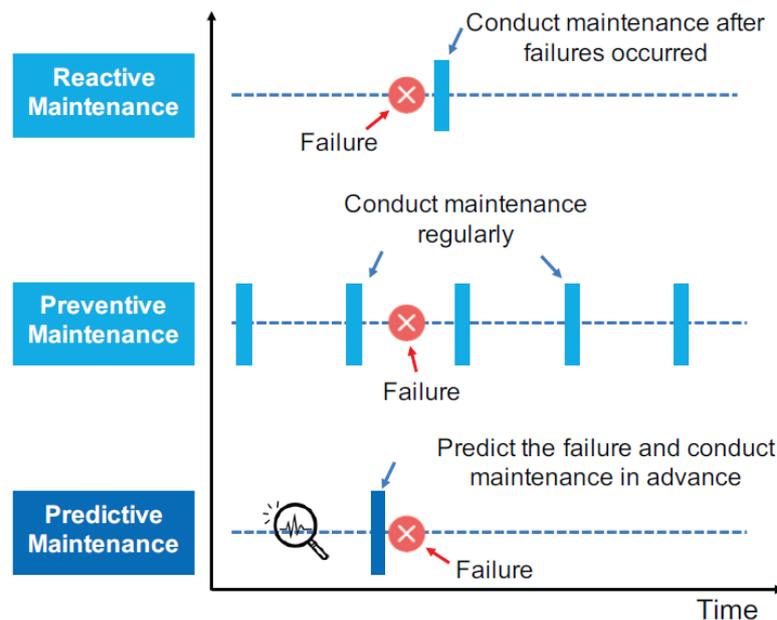
Por otra parte, la toma y el procesado de información adicional sobre el estado del motor en tiempo real nos permite modelar más fielmente la vida útil de los componentes, lo que nos permite tomar decisiones de mantenimiento más acertadas, acercándonos por tanto a nuestra concepción de planificación de mantenimiento óptima. Este es el punto de partida del mantenimiento predictivo, el cual analizaremos a continuación.

### 3.4. Mantenimiento Predictivo

El mantenimiento predictivo o PdM, aunque también denominado como CBM (Condition-Based-Maintenance) es una estrategia de planificación de mantenimientos que busca predecir cuando un componente es probable que falle y decidir que acción de mantenimiento tomar en consecuencia [15].

La correcta aplicación de esta estrategia nos permitiría anticipar los diferentes modos de fallo en los componentes, constituyendo por tanto la primera estrategia capaz de otorgarnos protección ante incidencias imprevistas, lo cual nos ofrece unas mayores garantías de seguridad respecto a las planificaciones previas, como se ilustra en la Figura 3.4.

Históricamente se han utilizado el RM y PM sin embargo, gracias a la evolución de la electrónica se han podido desarrollar sensores y sistemas capaces de medir diferentes variables durante la operación de una aeronave lo que ha permitido el desarrollo del PdM [16].



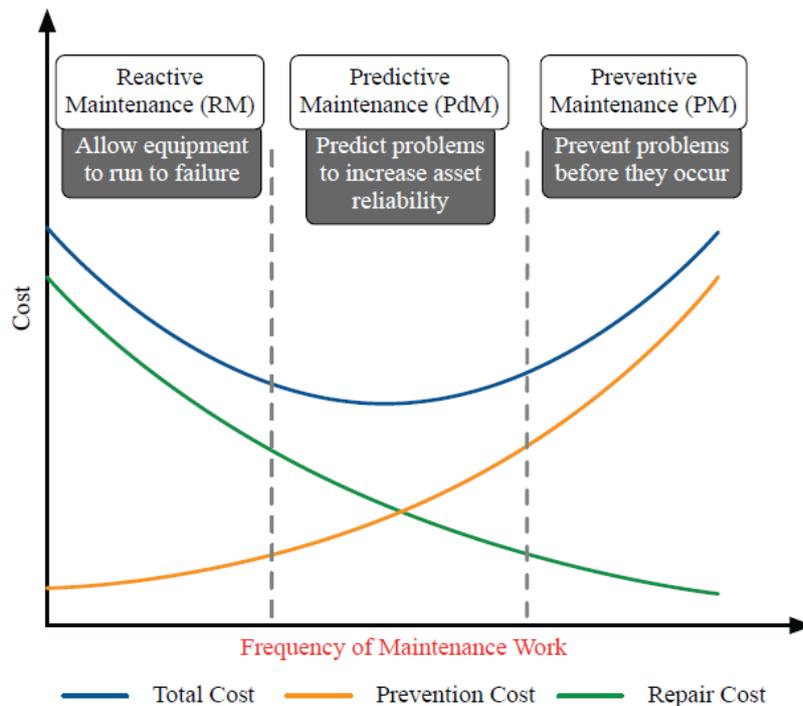
**Figura 3.4.** Esquema representativo de las estrategias de mantenimiento RM, PM Y PdM, PdM es la única capaz de predecir averías [9].

En la Figura 3.4 podemos observar el proceso de mantenimiento que se lleva a cabo con cada una de las tres estrategias de mantenimiento que hemos presentado. Como se explicó anteriormente, podemos ver que en el caso del RM el mantenimiento se realiza después de que haya ocurrido el fallo. En el caso del PM se realizan las tareas de mantenimiento en periodos concretos de tiempo para evitar que se produzca el fallo, sin embargo estos llegan a producirse debido a la componente aleatoria vista en la Figura 3.3. En el caso del PdM, al detectar cuando se va a producir una incidencia, podemos reducir las operaciones de mantenimiento a las mínimas necesarias (i.e., para prevenir el fallo inminente de un componente), tal y como se puede observar en la Figura 3.4.

El PdM es similar al PM ya que el objetivo es planificar las tareas de mantenimiento de forma que se pueda evitar el fallo [17]. Sin embargo, mientras que el PM planifica el mantenimiento en función de periodos de tiempo, en el PdM, esta planificación se hace en función de los datos recogidos por los sensores y los algoritmos de análisis que cualifican el estado del motor [18].

La correcta predicción del tiempo de vida útil restante o RUL (Remaining Useful

Life) nos permite explotar la totalidad de la vida útil de los diferentes componentes, evitando sustituciones innecesarias, así como la realización de paradas forzosas de la flota, reduciendo los costes asociados al mantenimiento significativamente, como se muestra en el gráfico comparativo mostrado en la Figura 3.5.



**Figura 3.5.** Comparación de los costes de del mantenimiento respecto a la frecuencia del mismo para las estrategias RM, PM y PdM [9].

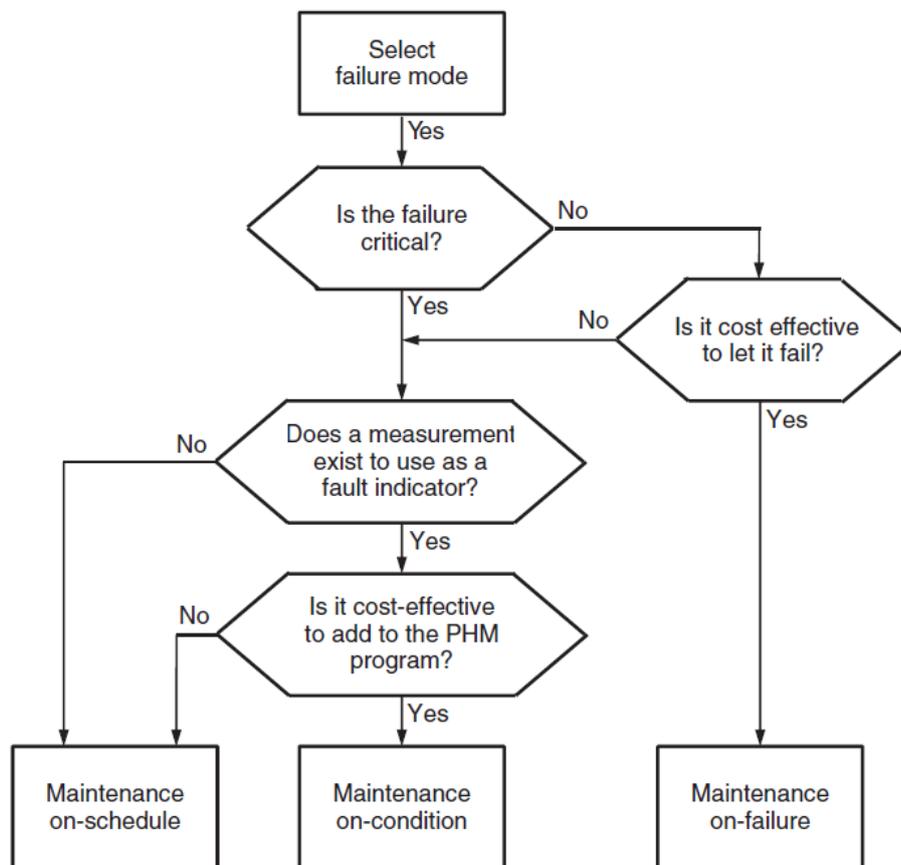
En la Figura 3.5 los costes de prevención se definen como aquellos utilizados en el reemplazo preventivo de un componente, mientras que los costes de reparaciones se entienden como aquellos en los que se incurre para poder cambiar una pieza después de que esta haya fallado [9]. Podemos observar que el RM tiene el menor coste de prevención debido a que no se realizar tareas de mantenimiento hasta que el componente falla, el PM tiene el menor coste de reparaciones debido a la buena planificación de las tareas de mantenimiento. Mientras que el PdM proporciona la mejor relación entre costes de reparación y prevención. Por ello con el avance de la tecnología se tiende hacia el mayor desarrollo del PdM ya que proporciona una disminución de los costes de mantenimiento.

Consecuentemente, este modelo de planificación nos permite acercarnos al concepto

de mantenimiento óptimo que perseguimos, ya que el PdM nos permitiría alcanzar las mayores garantías de seguridad con los menores costes de mantenimiento. No obstante, la viabilidad de esta estrategia reside en la efectividad de las metodologías perseguidas para la predicción de fallos.

El estudio de las mediciones, modos de fallo y algoritmos utilizados para su categorización se denomina PHM o *Prognostics and Health Monitoring* [2]. La hipótesis en la que se basa el desarrollo del PHM es que la buena localización de sensores a lo largo del motor va a permitir aislar y distinguir un problema concreto en el momento ocurra, por lo que permite realizar las tareas de mantenimiento de forma rápida y eficiente sin provocar periodos de gran inactividad. Para ello es necesario definir los indicadores de fallo, que como su propio nombre indica, se trata de mediciones que permiten predecir un modo de fallo del motor.

El estudio de los modos de fallo de un motor, así como de los indicadores de fallo es una tarea muy compleja y costosa en términos económicos, por lo que no siempre es rentable realizar PHM y por lo tanto PdM. En la Figura 3.6 podemos observar la estrategia de mantenimiento que se adoptará en función del modo de fallo y sus consecuencias tanto de seguridad como de costes.



**Figura 3.6.** Selección de la estrategia de mantenimiento a seguir en función de los indicadores de fallo y aspectos de seguridad y costes [2].

Sin embargo, la definición de los indicadores de fallos y por tanto, la predicción de fallos en motores de aviación constituye una tarea de gran complejidad [2]. Si bien podemos emplear sensores que nos otorguen información sobre el estado de los componentes, no todos los modos de fallo son directamente perceptibles y medibles por estos sensores como podemos observar en la Figura 3.6. Por ejemplo, no podemos medir durante el vuelo los cambios en la geometría de los álabes de la turbina como consecuencia del desgaste. No obstante, podemos inferir algunos de estos defectos y el estado general de los componentes a través de otros sensores de presión, temperatura o revoluciones por minuto entre otros, situados a lo largo del motor [2].

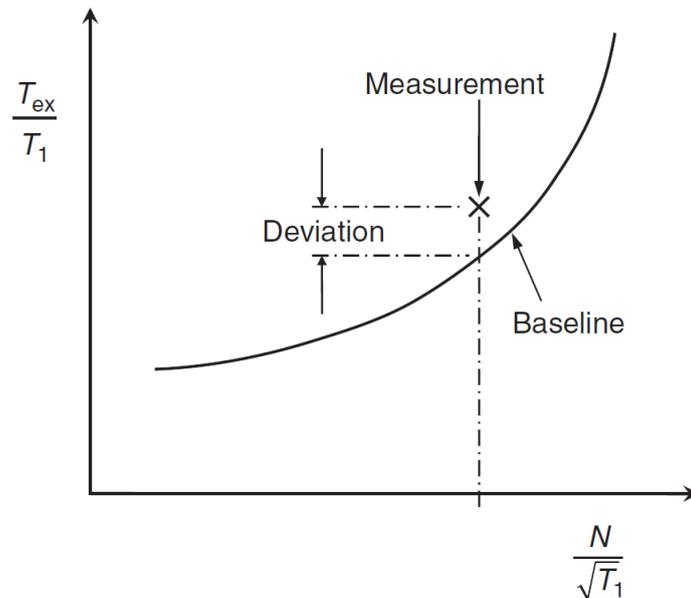
Por ello se desarrolla la librería de fallos que podemos observar en la Figura 3.7. Una librería de fallos es una matriz de datos donde las líneas representan las mediciones en relación a una medición de referencia, que sería la medición cuando el motor se

encuentra en perfecto estado, y las columnas son los modos de fallo. Esto permite identificar un modo de fallo en función de las tendencias que sigan las mediciones.

Measured parameter	Fault				
	F <sub>1</sub>	F <sub>2</sub>	F <sub>3</sub>	F <sub>4</sub>	F <sub>5</sub>
P <sub>m1</sub>	↑	↓	↓	—	↓
P <sub>m2</sub>	↓	↓	↑	↑	—
P <sub>m3</sub>	—	↑	↓	↑	
P <sub>m4</sub>	↑	↑	↑		
P <sub>m5</sub>	↓	↓	—		

**Figura 3.7.** Representación de la librería de fallos, donde las columnas representan diferentes modos de fallo y las filas cambios en las tendencias de las diferentes mediciones que permiten identificar los distintos modos de fallo listados [2].

En la Figura 3.8 podemos observar la medición que se realiza de la temperatura corregida en función de la velocidad de rotación corregida. En ella se representa la desviación de la medida en función de la línea de mediciones de referencia. Como podemos ver en este caso se trata de una desviación positiva, por lo que si esta medida fuera P<sub>m1</sub> de la librería de fallos indicaría que se va a producir el modo de fallo F<sub>1</sub> en la Figura 3.7.



**Figura 3.8.** Desviación percibida en el parámetro de la temperatura de la turbina respecto a la temperatura de entrada para una misma velocidad de rotación corregida, lo cual puede asociarse a una avería en la turbina [2].

Consecuentemente, las tendencias y los cambios de los valores percibidos por los diferentes sensores pueden representar un patrón asociado a un modo de fallo específico, de forma que, reconociendo el patrón, podemos predecir la avería antes de que suceda [19].

Sin embargo, lo habitual es que los patrones que desencadenan un fallo sean más complejos que tendencias en las mediciones, lo que dificulta la comprensión e identificación de estos patrones para un ser humano. No obstante, a lo largo de la literatura, podemos encontrarnos con algoritmos basados en ML (Machine Learning) capacitados para estas tareas [20].

No obstante, la viabilidad de estos algoritmos se encuentra supeditada a que se cumplan las siguientes premisas:

- Se ha de contar con un número de sensores suficiente para poder percibir el patrón de la avería de forma que no exista ambigüedad con otros patrones similares.
- Los sensores han de contar con la suficiente precisión para poder percibir los patrones.

- Ha de haber un registro de datos donde se asocie cada modo de fallo que se plantee detectar con el histórico de datos de mediciones que desencadena dicho fallo. Estos registros de datos, comúnmente denominados *datasets* en el ámbito de ML, son indispensables para poder entrenar los algoritmos que detectarán las averías de los motores.

La escasez de estos datasets en el sector de la aeronáutica representa uno de los mayores impedimentos de cara a la puesta en práctica de estas metodologías. No obstante, podemos encontrar datasets simulados por software como el CMAPSS (Commercial Modular Aero-Propulsion System Simulation) [21], programa comercial de la NASA, el cual se ha usado en los últimos años para el estudio y desarrollo de técnicas de PdM, las cuales revisaremos en el siguiente apartado.

Por último, a modo de resumen, se ofrece una tabla comparativa entre las diferentes estrategias de planificación de mantenimiento. Podemos destacar la mayor competitividad y seguridad del PdM respecto al resto de estrategias.

No obstante, la implementación del PdM requiere del desarrollo de metodologías entrenadas en contextos acordes a su campo de aplicación. El estudio de estas metodologías en búsqueda de la más adecuada para las necesidades de seguridad, eficiencia y escalabilidad del PdM en motores de aviación así como el análisis del contexto de los datos usados para el entrenamiento de estos algoritmos, buscando alcanzar una similitud de las mediciones con la aplicación real que facilite su implementación, es el punto en el cual toma lugar este Trabajo de Fin de Máster.

**Tabla 3.1.** Tabla comparativa de las diferentes estrategias de planificación del mantenimiento [9].

	<b>Beneficios</b>	<b>Desafíos</b>	<b>Aplicaciones</b>	<b>Desventajas</b>
<b>RM</b>	Máxima utilización del producto.	Averías parán explotación.	Componentes no críticos y redundantes.	El fallo de componentes produce problemas de seguridad.
	Menor coste de prevención.	Alto coste de recambio de piezas	Componentes de fácil reparación.	Se requiere disponibilidad completa de recambios.
		Potencial daño adicional al equipo.		
		Alto coste de reparación.		
<b>PM</b>	Bajo coste de reparación.	Necesidad de inventario.	Probabilidad de fallo que incrementa con el tiempo o uso.	Fallos aleatorios independientes del mantenimiento.
	Menor número de averías y menor tiempo de reparación.	Mayor tiempo de mantenimiento.		
		Cambios en componentes en buenas condiciones.		
<b>PdM</b>	Una visión holística del estado de los componentes.	Mayor coste de infraestructura e implementación (e.g., sensores).	Modos de fallo que puedan ser prevenidos de forma eficiente con un seguimiento.	No recomendable para modos de fallo que no sean rentables de realizar un seguimiento.
	Mayores opciones de análisis.	Sistema más complejo.		
	Previsión de averías.			
	Evita el recambio de componentes en buen estado.			

### 3.5. Investigaciones Previas

El estudio de las diferentes metodologías de mantenimiento constituye una línea de investigación actualmente activa y con gran potencial. Si bien podemos encontrarnos estudios centrados en la aplicación óptima de PM [22], y en el desarrollo de propuestas eficientes del RM [23], el principal enfoque en la literatura se centra en el estudio y puesta en práctica de metodologías de PdM.

El potencial de desarrollar un modelo de predicción de averías que reduzca los costes de mantenimiento y minimice los fallos resulta de gran interés para todos aquellos sectores donde los costes y consecuencias de una avería precisan de mantenimientos estrictos. Este interés es aún mayor en los casos en los que la realización de estos mantenimientos representa grandes pérdidas, ya sean directas (e.g., costes de recam-

bios, equipo, mano de obra) y/o indirectas (e.g., parada de la producción, pérdida de servicios, no disponibilidad de activos).

En consecuencia, a lo largo de la literatura podemos ver propuestas de aplicación centradas en aplicaciones industriales [24], instalaciones potencialmente peligrosas como centrales nucleares [25], instalaciones ferroviarias [26], infraestructura civil [27] y, conforme al objetivo de este trabajo, motores de aviación [28].

El estudio del mantenimiento predictivo de los motores de aviación representa un caso de aplicación de gran potencial. Al igual que en otros casos, existe un gran interés por desarrollar metodologías de mantenimiento en motores de aviación más eficientes y más seguras, lo que fomenta la investigación en este ámbito.

En cambio, las particularidades del sector aeronáutico acercan el desarrollo de modelos de predicción a su aplicabilidad real, ya que existe poca variabilidad en los diferentes motores de aviación comerciales en comparativa con otros sectores de aplicación, lo que facilita el entrenamiento de modelos particulares para cada motor [29].

Y, de forma análoga, es en la variedad de los diferentes algoritmos de predicción en lo que se ha centrado la literatura de este problema en los últimos años [30, 31, 32]. Podemos clasificar estos algoritmos y metodologías en función de su uso de la información y de su composición, resultando en tres grupos principales:

- El primer grupo acoge a los algoritmos basados en modelos [33]. Como indica su nombre, este grupo de metodologías parten de modelos que reflejan el comportamiento del sistema. La unión de este modelo con mediciones reales permite realizar predicciones sobre el RUL de los componentes, obteniendo una mayor exactitud en estas predicciones en comparación con otros modelos [34].

No obstante, para ciertos casos de aplicación, como el aeronáutico, resulta ampliamente costoso, si no imposible, el desarrollo de modelos exactos de degradación y fallo, lo que limita su rango de aplicación [35]. Sin embargo, podemos ver aplicaciones aeronáuticas en componentes más simples de modelar, como es el caso de los actuadores y la aviónica [36, 37].

- El segundo grupo engloba a todas aquellas metodologías que emplean datos in-

dependientes de modelos para predecir el estado de los componentes y, en consecuencia, su RUL. Dentro de esta definición se encuentran las metodologías de ML y modelos de grafos [38, 39, 40].

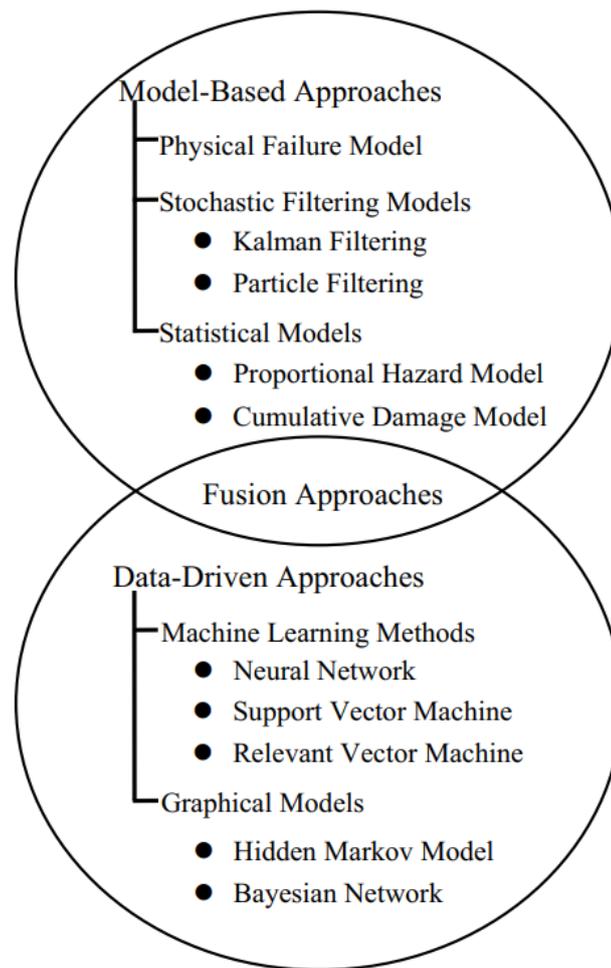
Los algoritmos basados en ML son de gran interés como consecuencia de su capacidad para afrontar problemas de gran dimensionalidad con un gran número de variables. Sin embargo, su aplicación se ve comprometida por la ausencia de bases de datos para entrenarlos, particularmente en el sector aeronáutico.

No obstante, podemos encontrarnos con un gran número de propuestas de diferentes metodologías para el campo de la estimación del RUL en motores de aviación. Entre estas metodologías, podemos destacar la aplicación Regresión Lineal [41], Redes Neuronales Artificiales o ANN (Artificial Neural Networks) [42], bosques aleatorios o Random Forests [43], Redes Neuronales Convolucionales o CNN (Convolutional Neural Network) [44] y las redes LSTM (Long Short-Term Memory) [45] por sus prestaciones y su potencial en este campo. En la Sección 4 profundizaremos sobre el fundamento de algunas de estas metodologías, así como la comparativa entre estas para el caso de estudio que nos ocupa.

- El último grupo consiste en una combinación de los anteriores modelos, por lo que se define como aproximación por fusión, más comúnmente conocido por su término en inglés, *ensemble methods* [46]. Como bien representa la Figura 3.9, estas metodologías de fusión pueden combinar algoritmos basados en modelos y basados en datos, constituyendo una metodología superior con respecto a sus algoritmos de partida [47].

No obstante, también puede originarse un algoritmo que fusione metodologías del mismo grupo, lo que permite sobrepasar las limitaciones de algoritmos concretos [48].

Al realizar un estudio sobre las metodologías de mantenimiento predictivo aplicadas a la estimación del RUL en motores de aviación, podemos encontrarnos un gran abanico de diferentes técnicas para este fin. Si bien todas estas técnicas se encuentran aplicadas al caso aeronáutico y parten de la base de datos de un turbofan comercial (i.e., CMAPSS) no todos estos artículos se centran en el marco aeronáutico.



**Figura 3.9.** Clasificación de los principales algoritmos de predicción de RUL [30].

La accesibilidad, complejidad y aplicabilidad de la base de datos CMAPSS de la NASA, la ha convertido en un campo de pruebas para el desarrollo de metodologías de ML. Como consecuencia, numerosos artículos en la literatura emplean esta base de datos como un banco de pruebas o *benchmark* de las prestaciones de los nuevos algoritmos que desarrollan, sin prestar especial consideración al origen de los datos, su contexto y la implementabilidad y escalabilidad de las metodologías propuestas sobre el sector aeronáutico [49].

Como consecuencia, la línea del desarrollo de metodologías para la predicción de averías en motores de aviación se cruza con otra línea de investigación, centrada en el desarrollo de nuevas metodologías de ML y su aplicación para el caso de predicción de averías. La diferencia entre estas dos líneas radica en el acercamiento al marco en el que se encuentra el mantenimiento de los motores por el segundo caso.

A la hora de proponer modelos de PdM para este fin, no todos los artículos dan respuesta en la literatura a las principales problemáticas de estas metodologías de cara a su aplicación real en el sector aeronáutico, como la escalabilidad, robustez e implementabilidad en el mercado actual.

Dentro de este aspecto, el entrenamiento de modelos sujetos a condiciones de incertidumbre representa un pilar esencial de cara a la aplicabilidad de estos algoritmos en el sector aeronáutico [30]. El uso de bases de datos simuladas acarrea el error, o la ausencia de él, de los modelos sobre las que están basadas.

Bases de datos como el CMAPSS no tienen en consideración todos los modos de degradación y fallo posibles, y los valores de las mediciones que devuelven no contienen las incertidumbres presentes en los sensores que toman estas mediciones a bordo del motor [31].

La validez de las mediciones representa un aspecto fundamental en el desarrollo de estas metodologías de mantenimiento predictivo. Los algoritmos basados en datos entrenan su capacidad de predicción a partir de estos datos, por lo tanto, un cambio en las incertidumbres de los sensores no reflejada en la base de datos inicial puede desencadenar el fracaso del algoritmo para su labor de mantenimiento predictivo [50].

Si bien podemos encontrar artículos centrados en el desarrollo de nuevas bases de datos, derivadas del CMAPSS, como es el caso de la N-CMAPSS [51], la cual incorpora modelos de degradación de componentes y ruido en la incertidumbre de los sensores. El ruido de estos sensores se asume como constante en el tiempo, obviando por tanto los efectos de la deriva de los sensores como consecuencia de las condiciones extremas a las que se exponen [52].

Consecuentemente, en este Trabajo de Fin de Máster se propone, por primera vez en la literatura, evaluar la influencia de la deriva de los sensores de un motor de aviación en sus mediciones, aplicando un modelo de degradación que simule dicha deriva a la base de datos CMAPSS para el entrenamiento de modelos de predicción de fallos.

Esta base de datos constituirá un marco de estudio y comparativa de las metodologías de mantenimiento predictivo, lo que nos permitirá evaluar cuál es la más

indicada, considerando tanto los resultados obtenidos de predicción así como la complejidad, facilidad de implementación y escalabilidad de estas metodologías de cara a su aplicabilidad al sector aeronáutico.

## 4. Metodologías de inteligencia artificial empleadas en PdM

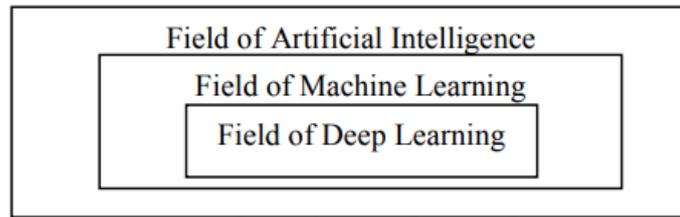
Aunque los estudios de investigación y aplicabilidad de la inteligencia artificial o IA están muy presentes en la actualidad, en la década de los 50 ya se realizaron estudios sobre el desarrollo de esta disciplina como por ejemplo los desarrollos de McCulloch y Pitts en 1943 y el libro *Perceptrons* en 1969 publicado por Minsky y Paper en el área de estudio de las ANN [53].

Sin embargo, debido a la limitación de recursos computacionales, si bien se estudió la base teórica no se pudieron llevar a cabo grandes desarrollos experimentales. No obstante, con los avances de los que disponemos en la actualidad se han llevado a cabo trabajos de investigación sobre desarrollos de nuevos algoritmos y la aplicabilidad de estos en distintos sectores de la sociedad como la industria o medicina [54].

Antes de poder aplicar la IA y sus metodologías a nuestro caso de estudio veremos unas definiciones o nociones básicas. Podemos definir IA como aquellas técnicas que dotan a los ordenadores de capacidades para imitar comportamientos del cerebro humano como por ejemplo pensar, memorizar o aprender. Para ello, es imprescindible conseguir que la máquina interprete la información disponible, generar estructuras para facilitar su aprendizaje y metodologías para validar el conocimiento generado.

Dentro de la inteligencia artificial podemos distinguir el ML que son aquellas técnicas o algoritmos que confieren la capacidad de aprender a los ordenadores por sí mismos a partir de conjuntos de datos [55]. Con esta información, las máquinas pueden tomar decisiones en contextos similares a los de entrenamiento con el fin de poder realizar predicciones, identificar patrones o interactuar con el entorno de forma autónoma.

Además dentro del ML podemos diferenciar el Deep Learning o DL que está caracterizado principalmente por el uso de redes neuronales densas, es decir compuestas por varias capas ocultas, en sus algoritmos.



**Figura 4.1.** Esquema representativo de las subdivisiones dentro de la IA [55].

Dentro del ML, en función del método de aprendizaje del algoritmo podemos encontrar tres disciplinas: Aprendizaje Supervisado, Aprendizaje No Supervisado o Aprendizaje por Refuerzo.

El Aprendizaje Supervisado representa el conjunto de algoritmos que se utilizan para clasificar o predecir los valores que se asocian con una instancia de datos desconocida de manera automática a partir del entrenamiento de estos algoritmos con un conjunto de datos etiquetado del que se conoce su verdad absoluta [56]. Esta disciplina se divide en dos categorías principales: Clasificación y Regresión.

- **Clasificación:** Consiste en utilizar los datos de los atributos que recopilamos sobre una nueva instancia desconocida con el fin de poder etiquetarla con unas clases objetivo para las que los algoritmos han sido entrenados. De forma matemática, la clasificación se puede definir como el uso de algoritmos que permiten definir las fronteras (rectas/planos/hiperplanos) que separan las clases objeto de predicción a través de los algoritmos empleados para etiquetar datos desconocidos [57].
- **Regresión:** Consiste en determinar valores cuantitativos asociados con características no determinadas (no medidas de forma directa) en las instancias de datos desconocidas que se estén analizando. La regresión se vincula con la obtención de las curvas espaciales que mejor ajusten la determinación de los valores de ciertas clases desconocidas a partir de los datos medidos disponibles de atributos que se encuentran relacionados con la clase que se pretende predecir.

Se puede definir el Aprendizaje No Supervisado como el conjunto de algoritmos que permiten encontrar patrones con los que relacionar instancias de datos diferentes

encontrando similitudes entre ellos con el fin de agruparlos de forma inteligente, encontrar nuevas formas de maximizar la utilidad de la información del conjunto de datos analizado y relacionar atributos diferentes en función de su similitud [58].

Las técnicas de Aprendizaje No Supervisado son utilizadas cuando tenemos un conjunto de datos del que no poseemos el etiquetado, es decir no sabemos cual es su verdad absoluta y por lo tanto no podemos aplicar metodologías de Aprendizaje Supervisado. Estos algoritmos se utilizan principalmente para separar las instancias en grupos que presenten gran similitud, y por lo tanto se pueda extraer conocimiento de estas agrupaciones aunque no se pueda llegar a comprobar con la verdad absoluta ya que no disponemos de ella.

Incluso, en clases amplias (una vez etiquetadas) puede ser necesario profundizar en mayor medida para predecir subclases dentro de la clase principal sin que los algoritmos de aprendizaje supervisado hayan sido entrenados para esta tarea. Las tres grandes disciplinas del Aprendizaje No Supervisado son el Agrupamiento o Clustering, la Reducción de la Dimensionalidad y los Sistemas de Recomendación [59].

- **Agrupamiento:** Consiste en definir grupos de datos (clusters) que tienen una gran similitud entre ellos y a la vez presentan una disimilitud suficiente con el resto de datos estudiados. Permite estudiar posteriormente relaciones entre los datos y otorgar una explicación a la razón por la que se produjo de este agrupamiento.
- **Reducción de Dimensionalidad:** Es un proceso que permite definir el conjunto de atributos más relevante para expresar la información contenida en un conjunto de datos. También abarca el proceso de expresar estos datos de la forma más interesante posible para maximizar la diversidad entre los datos mediante la definición de nuevas variables que permitan extraer la mayor varianza entre los datos que analicemos.
- **Sistemas de Recomendación:** Busca similitudes entre elementos para definir la asociación más probable de un conjunto de datos aportado con otro elemento de un conjunto de estudio.

Hay ciertas ocasiones en las que no disponemos del etiquetado de la totalidad de

las instancias presentes en la base de datos y por lo tanto no tenemos la capacidad de implementar las metodologías de Aprendizaje Supervisado, en este supuesto se trabaja con la disciplina denominada Aprendizaje Semisupervisado [60].

Por este motivo, es muy común utilizar la información disponible por el pequeño conjunto de datos que sí se encuentra etiquetado para poder etiquetar, mediante técnicas de Aprendizaje No Supervisado, otros elementos por similitud y efectuando evaluaciones de probabilidad de pertenencia a cada clase final con el fin de poder asignarles una etiqueta y poder llevar a cabo el uso de los algoritmos de Aprendizaje Supervisado [60]. Por ello, el Aprendizaje Semisupervisado se define como el conjunto de técnicas que trabajan con un conjunto de datos donde se encuentran instancias etiquetadas y no etiquetadas que permiten mejorar los resultados de clasificación o regresión de modelos que se entrenasen exclusivamente con los datos etiquetados.

El Aprendizaje Reforzado, Reinforcement Learning o RL es una disciplina del ML en la que un agente interactúa con un entorno habitualmente estocástico con la finalidad de aprender a seleccionar las mejores acciones en cada estado que le permitan maximizar las recompensas que obtenga durante su aprendizaje [61].

Esta disciplina también se encuentra en un punto intermedio entre el Aprendizaje Supervisado (ajusta sus algoritmos de toma de decisiones en base a un histórico de datos etiquetado) y del Aprendizaje No Supervisado (habitualmente no se pueden analizar todos los estados posibles que el agente podría alcanzar en el entorno y toma las decisiones por proximidad de los estados con otros conocidos).

No obstante, esta disciplina se aleja de los otros dos pilares del ML ya que en ella el agente interactúa directamente con el entorno, genera los datos de entrenamiento y recibe un feedback del entorno en función de la calidad que consiga en la toma de decisiones [62]. Además, mientras las bases de datos con las que se aplican los algoritmos de ML supervisado y no supervisado son fijas, el agente de RL explora el entorno para poder descubrir cómo debe interactuar con él generando nuevos datos.

En esta exploración, la habitual estocasticidad del entorno en los problemas de RL hace que el agente tenga que lidiar con la incertidumbre y por ello tienda a maximizar la utilidad de sus acciones sabiendo que la toma de una acción concreta no siempre va

a alcanzar el objetivo deseado.

Esto último también provoca que la toma de decisiones del agente de RL y su aprendizaje no estén exclusivamente ligados a la obtención de resultados en el momento presente sino que busca maximizar las recompensas en un horizonte temporal definido durante el entrenamiento [61].

Aunque hemos definido las características y particularidades de cada una de las disciplinas que componen en el ML, en este Trabajo de Fin de Máster nos vamos a centrar en la utilización de métodos de Aprendizaje Supervisado. Esto se ha decidido debido a la naturaleza de la base de datos, donde tenemos disponible el etiquetado de todas las instancias. En el desarrollo de nuestro problema implementaremos los algoritmos de Regresión Lineal, Random Forest y ANN, por ello realizaremos un estudio a continuación sobre sus principales características.

## 4.1. Regresión Lineal

El algoritmo de Regresión Lineal es el tipo de algoritmo más simple para realizar predicciones. En la Regresión Lineal el algoritmo se entrena mediante la búsqueda de relaciones lineales entre los atributos y la clase o etiqueta [41].

Podemos encontrar dos tipos de algoritmos de Regresión Lineal en función de la dimensión de los atributos o columnas de datos. De esta forma, podemos encontrar la Regresión Lineal Simple si tenemos una dimensión de atributos o Regresión Lineal Múltiple en caso de tener mayor dimensionalidad.

Teniendo en cuenta que partimos de una base de datos representada por  $(x_i, y_i)_{i=1}^N$  donde cada instancia  $x_i$  tiene su etiqueta  $y_i$  y  $N$  es la dimensión de la base de datos [63]. El objetivo es crear un modelo  $f_{w,b}(X)$  que sea una combinación lineal de las instancias, de forma que:

$$f_{w,b}(X) = \mathbf{w}\mathbf{x} + b \quad (4.1)$$

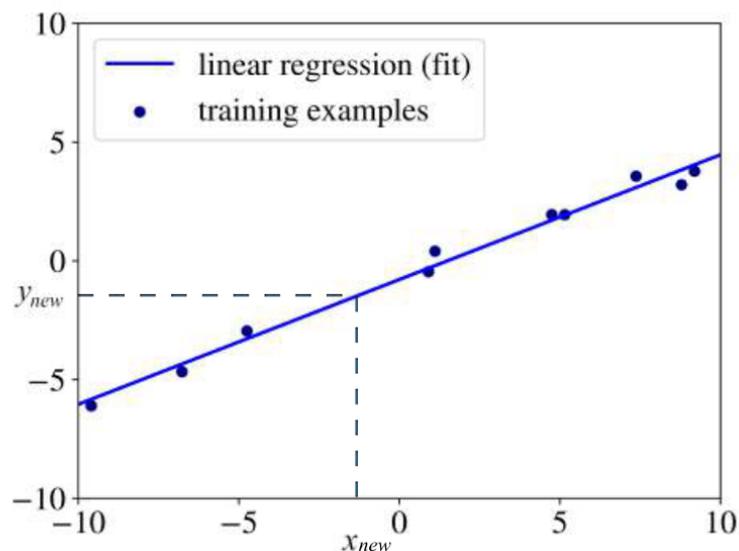
Donde  $\mathbf{w}$  es un vector de parámetros de dimensión  $N$  y  $b$  es el parámetro indepen-

diente. Por lo que este modelo está caracterizado por los parámetros  $b$  y  $w$ .

Este modelo se utiliza para predecir las etiquetas del conjunto test de la base de datos. En función de los parámetros utilizados para entrenar el modelo se producirán resultados diferentes, y por lo tanto para una instancia dada se producirían estimaciones diferentes.

De esta forma, se persigue encontrar los parámetros óptimos que permitan realizar las mejores predicciones [41]. Para ello se define una función de coste que es función de los parámetros de forma que cuanto menor sea esta función, mejor sea el ajuste del modelo, y por tanto la predicción alcanzada. Algunas de las funciones de coste más utilizadas son MSE o Mean Squared Error y RMSE o Root Mean Squared Error.

Cuando hemos definido la función de coste tendremos que utilizar algoritmos de búsqueda que se encargan de generar valores para los parámetros de forma que la función de coste se minimice en cada iteración. El algoritmo más utilizado es el Descenso de Gradiente o SGD (Stochastic Gradient Descent) [64]. Sin embargo no vamos a profundizar en estos algoritmos de búsqueda ya que se encuentran fuera del alcance de este Trabajo de Fin de Máster.



**Figura 4.2.** Ejemplo del Resultado obtenido mediante Regresión Lineal Simple [63]

El modelo final debería encontrarse lo más cercano posible a las instancias de entrenamiento. En la Figura 4.2 podemos observar la recta obtenida en comparación con

las instancias de entrenamiento.

Como se puede observar en la Figura 4.2, dada una instancia desconocida por el algoritmo este puede hacer la predicción. Cuanto más cercana sea la recta obtenida por el algoritmo a las instancias de entrenamiento, mayor precisión obtendremos en la predicción.

En el caso de Regresión Lineal Múltiple en lugar de una recta tendríamos planos o hiperplanos en función de la dimensionalidad [63].

Las principales ventajas de la Regresión Lineal son:

- Simplicidad del modelo: El modelo está definido únicamente por una ecuación matemática basada en una combinación lineal de los atributos.
- Fácil interpretabilidad del modelo: El modelo es fácil de interpretar ya que se puede ver de forma sencilla la importancia de cada atributo mediante la magnitud de su coeficiente asociado.
- Gran eficacia en problemas lineales: Cuando tenemos un problema lineal el modelo se ajusta muy bien a la realidad.
- Tiempo de ejecución de entrenamiento y predicción cortos debido a la simplicidad del modelo.

La principal desventaja de esta metodología es que es muy sensible a los *outliers* o datos que se distancian del resto de instancias.

## 4.2. Random Forest

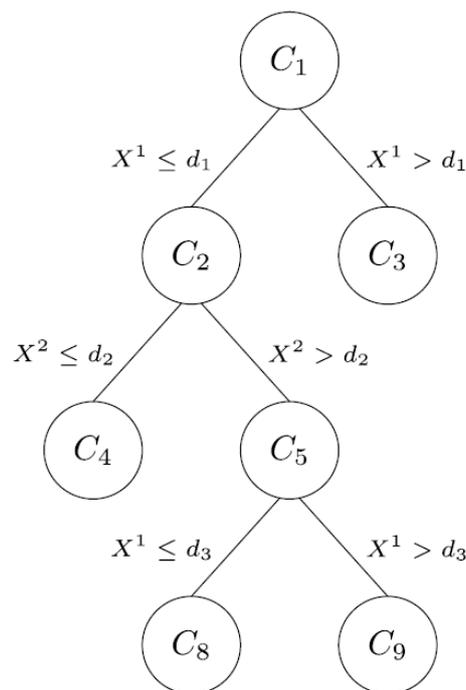
Esta metodología está basada en el uso de gran cantidad de Árboles de Decisión. Por lo que comenzaremos explicando las nociones básicas de esta metodología.

Los Árboles de Decisión se pueden utilizar tanto para resolver problemas de clasificación como de regresión. En este último caso tomaría el nombre de Árbol de Regresión aunque la construcción del modelo se realiza de forma análoga.

Este método se basa en un nodo principal o raíz que se bifurca en dos nodos que pueden ser nodos de decisión, también denominados ramas, o nodos finales también denominados hojas. En los nodos de decisión las instancias son clasificadas en función de sus características [65].

Estos nodos a su vez se separan en dos más y así sucesivamente hasta llegar a las hojas que describirían las clases de la base de datos. En cada una de estas bifurcaciones se utiliza un solo atributo, el que mejor discrimine las instancias en las diferentes clases. De forma que se acaba obteniendo la clasificación o la estimación en función de si se trata de un problema de clasificación o regresión.

En el caso de los Árboles de Decisión la elección de los atributos que formarán parte de los nodos de decisión se realiza mediante el estudio de la Ganancia de Información, sin embargo este aspecto es interno al algoritmo y no se encuentra dentro del alcance de este Trabajo de Fin de Máster.



**Figura 4.3.** Árbol de Decisión para la predicción de la clase de un valor dado  $x$  [66]

En la Figura 4.3 podemos observar que cuando la condición se cumple, esas instancias se clasifican al lado izquierdo y en caso contrario lo hacen en el lado derecho [65]. La

principal desventaja es que este algoritmo es altamente dependiente de los datos, por lo que una pequeña modificación en la base de datos puede dar lugar a un Árbol de Decisión completamente diferente. Por lo tanto, este algoritmo puede presentar problemas en la generalización u overfitting que estudiaremos en la Sección 6.

La metodología de Random Forest se basa en la combinación de Árboles de Decisión que se crean de forma aleatoria [7]. De esta forma se evita el gran efecto de dependencia de los datos que tienen los Árboles de Decisión.

El primer paso para crear un Random Forest es la realización de Bootstrapping o método de remuestreo. Este método consiste en la creación de nuevas bases de datos a partir de la base de datos de partida. Crearemos tantas nuevas bases de datos como árboles que queramos que pertenezcan a nuestro bosque. Estas nuevas bases de datos tendrán un número aleatorio de instancias y estarán formadas por los conjuntos instancia-atributos-clase de la base de datos original [63]. Sin embargo, contendrá estas instancias de forma aleatoria, es decir, las nuevas instancias no se encontrarán en el mismo orden que en la base de datos original y además pueden repetirse estas instancias.

A diferencia del caso de los Árboles de Decisión, en el caso de Random Forest la elección de los atributos, y por tanto la distribución de los nodos de decisión, que utilizaremos para entrenar el modelo de cada árbol se hace de forma aleatoria. Esto se realiza para que de esta forma los Árboles de Decisión obtenidos sean lo más diferentes posible, para reducir el efecto de la dependencia del desempeño del algoritmo con los datos de partida.

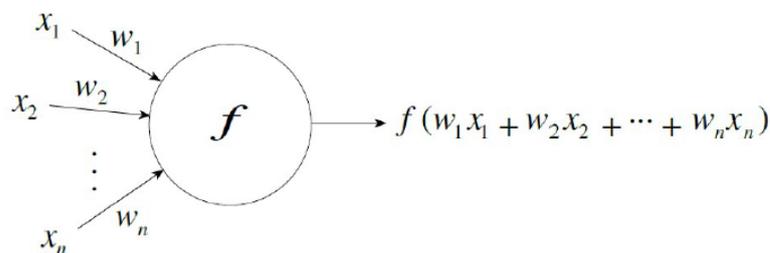
Una vez se han creado los diferentes árboles que forman el Random Forest se introducen las instancias de test para obtener la predicción. Debido a la gran variedad en la estructura de los árboles se obtendrán diferentes resultados en cada uno. En un problema de clasificación la predicción resultante se obtendrá de realizar la mayoría entre los resultados obtenidos por todos los árboles [66]. En un problema de regresión la predicción resultante será la media de los resultados obtenidos. Este proceso de combinar resultados de múltiples modelos se denomina Aggregation. por lo tanto, en la implementación de Random Forest se realiza Bootstrapping y posteriormente

Aggregation. Esto se conoce como Bagging.

### 4.3. Artificial Neural Networks

La metodología ANN basa su desarrollo en la simulación del funcionamiento del cerebro humano. Está definida por neuronas conectadas entre sí de forma que obtengamos la predicción en la capa de salida.

La unidad más básica que forma las ANN se denomina perceptrón y es cada una de las neuronas que forman la red.



**Figura 4.4.** Representación de un perceptrón [67].

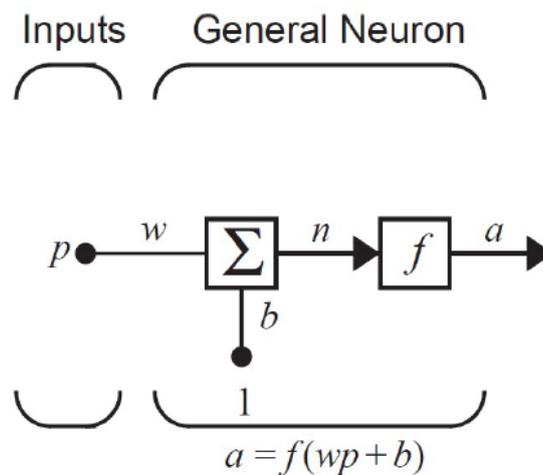
En la Figura 4.4 podemos observar cada una de las instancias  $x_j$  que llegan a la neurona. Estas instancias tienen unos pesos asociados  $w_j$  por los que se multiplican. Estos pesos tienen valores normalmente comprendidos entre 0 y 1 según la importancia que tenga la información de la instancia. Finalmente cuando esta información llega a la neurona se le aplica una función de activación.

Esta función de activación es uno de los hiperparámetros que caracterizan la red y es la que añade la no linealidad a las ANN [67]. Algunas de las funciones de activación más utilizadas son:

- Sigmoide: Las entradas a esta función de activación están comprendidas entre  $(-\infty, \infty)$  y en la salida son convertidas al intervalo  $[0,1]$
- Tangencial o tangente hiperbólica: Las entradas a esta función de activación están comprendidas entre  $(-\infty, \infty)$ , como en el caso de la sigmoide, pero las salidas están comprendidas en el intervalo  $[-1,1]$

- Rectificador o ReLU (Rectified Linear Unit): En esta función de activación las entradas negativas se convierten a 0, mientras que las entradas positivas no varían. Esta función de activación es la más utilizada, sobre todo en las capas ocultas.

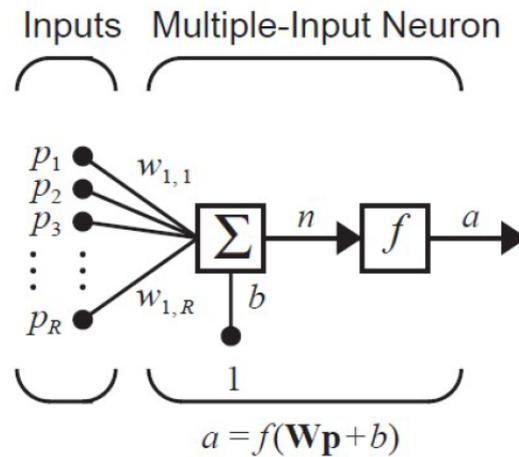
Las ANN están formadas por la combinación de componentes más simples. Por esta razón, definiremos los hiperparámetros y ecuaciones que las rigen mediante la definición de modelos a los que progresivamente añadiremos complejidad.



**Figura 4.5.** Representación de una neurona con una única entrada [68].

En la Figura 4.5 podemos observar la representación de una neurona con una única entrada que es un escalar  $p$ . Este escalar se multiplicará por su peso  $w$ . Otro de los hiperparámetros que caracterizan las ANN son los *bias* o sesgos denotados en esta figura como  $b$  [68]. Este sesgo se suma a la multiplicación anterior y se le aplica la función de activación para obtener la predicción  $a$ .

Comúnmente las neuronas tienen varias entradas, por lo que definiremos las neuronas de entrada múltiple, como se puede ver en la Figura 4.6.



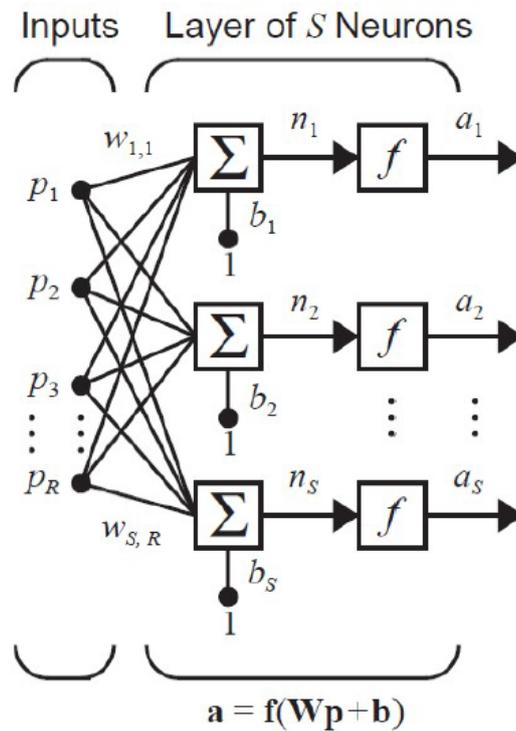
**Figura 4.6.** Red neuronal de entrada múltiple [68].

Realizando el estudio análogo al caso de neurona con una única entrada llegamos a la ecuación de predicción:

$$a = f(\mathbf{w}\mathbf{p} + b) \quad (4.2)$$

En este  $\mathbf{w}$  y  $\mathbf{p}$  no son escalares, si no vectores donde se recogen cada uno de los pesos y cada una de sus entradas correspondientes respectivamente.

Mediante la combinación de varias neuronas de entrada múltiple podemos formar una capa de neuronas como la descrita en la Figura 4.7



**Figura 4.7.** Representación de una capa de neuronas [68].

En este caso el resultado obtenido se puede calcular como:

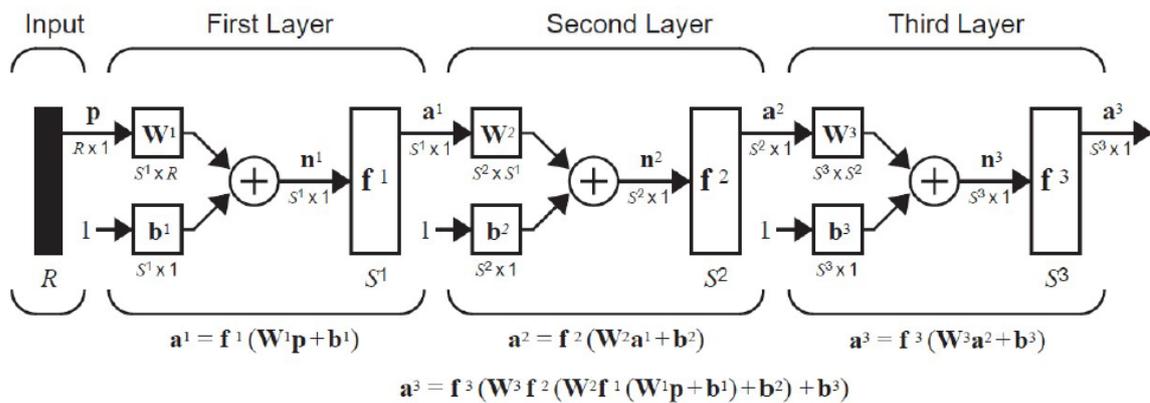
$$\mathbf{a} = \mathbf{f}(\mathbf{W}\mathbf{p} + \mathbf{b}) \quad (4.3)$$

Donde  $\mathbf{a}$  representa el vector de valores resultado, ya que tendremos tantos resultados como neuronas tenga nuestra capa. En este caso  $\mathbf{b}$  también será un vector de dimensión el número de neuronas.  $\mathbf{W}$  será una matriz de dimensión  $S \times R$  según la notación de la Figura 4.7, donde  $S$  indica el índice de la neurona de destino y  $R$  indica la neurona de partida.

Finalmente, analizaremos la estructura más común de ANN, que suelen estar compuestas por varias capas. La capa que contiene las diferentes entradas se denomina capa de entrada y contiene tantas neuronas como atributos posea la base de datos que se vaya a entrenar. La capa que contiene las neuronas con las predicciones del modelo se denomina capa de salida [68]. En la capa de salida tendremos tantas neuronas como sean necesarias para caracterizar la predicción. El resto de capas que posea la red se

denominan capas ocultas. En el caso que podemos observar en la Figura 4.8 tenemos la capa de entrada, la de salida y dos capas ocultas.

Cada una de estas capas está caracterizada por la Ecuación 4.3 por lo que al añadir mayor número de capas y neuronas aumenta la complejidad del problema.



**Figura 4.8.** ANN con dos capas ocultas [68].

El rendimiento de este algoritmo es altamente dependiente de todo su gran número de hiperparámetros. Por ello tienen gran importancia los valores que se asignan a los pesos y sesgos de cada una de las neuronas de la red. Al comienzo del entrenamiento de las ANN se inicializan estos hiperparámetros pero se actualizan en cada iteración. Esto se realiza mediante el proceso denominado backpropagation o retropropagación que normalmente se realiza mediante SGD [67]. Este proceso se basa en el estudio de la función de coste una vez obtenido el resultado de la ANN. Con el valor de la función de coste se realiza el retroceso en la red actualizando los valores de pesos y sesgos para realizar la siguiente iteración.

La principal ventaja de este algoritmo de predicción es su menor dependencia de los datos en relación con las metodologías estudiadas anteriormente [7]. No obstante presenta ciertas desventajas como que ya que son modelos más complejos necesitan mayor tiempo de entrenamiento y además es una metodología en la que no es posible saber la razón por la que ha llegado a cierta conclusión. Además de esto, para realizar un entrenamiento eficaz de las ANN es necesaria una base de datos de gran tamaño.

## 5. Mediciones en Motores de Aviación

Las metodologías de mantenimiento predictivo que hemos estudiado en la anterior Sección representan modelos de predicción basados en datos. Consecuentemente, estos algoritmos fundamentan su metodología de predicción en el estudio y entrenamiento sobre un conjunto de datos.

La similitud entre el conjunto de datos con el que se ha realizado el entrenamiento y los datos que engloban su puesta en uso constituye un pilar fundamental para la aplicabilidad de estos modelos.

En el contexto de este Trabajo de Fin de Máster, los datos de los que partimos son las mediciones que toman los diferentes sensores presentes en la operación de un motor de aviación. Estos sensores tienen la función de controlar y monitorizar el estado del motor, otorgando información a la unidad de control electrónico del motor, más comúnmente conocida por sus siglas en inglés, ECU (Electronic Control Unit) [69]. Este sistema se encarga de regular diferentes parámetros del motor para satisfacer las necesidades de navegación de la aeronave.

Consecuentemente, podemos partir de estas mediciones para desarrollar nuestro modelo. No obstante, hemos de buscar alcanzar esta similitud entre las mediciones con las que entrenamos el algoritmo de predicción y las mediciones que recibirá con su puesta en servicio.

Sin embargo, múltiples factores pueden comprometer esta equivalencia entre los datos de entrenamiento y los datos que recibirá en su puesta en servicio. Cambios en las condiciones de vuelo, diferentes tipos de avión y, más notoriamente, diferentes tipos de motor pueden provocar cambios en la homogeneidad del conjunto de datos, desencadenando deficiencias en el comportamiento de nuestro algoritmo de predicción.

Por otra parte, la ausencia de datos del sector aeronáutico sobre mediciones de motores nos impide realizar un entrenamiento con datos reales de la operación de un motor, lo que nos obliga a acudir a entornos de simulación como el CMAPSS, el cual nos permite generar las mediciones buscadas a partir de un modelo de un motor.

Si bien las bases de datos extrapolables de este modelo son bien fundadas, sobre las que entraremos en la siguiente Sección, hay ciertos aspectos que la diferencian de un motor real. Para empezar, el modelo de motor empleado del CMAPSS contiene únicamente dos modos de fallo, la degradación del compresor de alta presión HPC (High Pressure Compressor) y la degradación del fan del motor [70].

Estos modos no constituyen todas las causas de avería en motores, y la espontaneidad de las averías no siempre puede recogerse bajo modelos exactos [71]. Por otra parte, las mediciones que nos devuelve CMAPSS se acogen a un modelo de turbofan simulado. Consecuentemente, imperfecciones en el modelado del ciclo y comportamiento del motor pueden desencadenar cambios en las mediciones tomadas al extrapolarlo a un motor turbofan real equivalente.

Sin embargo, estas variaciones no solo pueden venir tomadas como consecuencia de las imperfecciones del modelo. Las incertidumbres y errores en la medición de los sensores también son un factor de notable importancia en este aspecto. Si bien en estos modelos no se considera la existencia de error alguno de medición, ya que se trata de un modelo simulado, en la práctica todos los sensores están sujetos a una incertidumbre y un error que provoca cambios en el valor de la medición aportada respecto a la real.

Esto puede desencadenar un cambio significativo en la homogeneidad de los datos, ya que, en función de estos valores de incertidumbre, podemos desmontar las relaciones que los algoritmos de predicción hayan llegado a realizar. Consecuentemente, de cara a realizar un modelo de predicción fiel a la realidad, hemos de buscar introducir medidas de este error a nuestro modelo de entrenamiento, en caso de ser simulado.

Si bien ciertos autores aplican ruido a estas mediciones, este ruido se suele introducir como una función gaussiana, constante en el tiempo. Esto no es siempre aplicable, ya que ciertos sensores, en función de sus condiciones de operación y su nivel de exposición a condiciones severas, pueden sufrir una deriva que afecte a su nivel de incertidumbre con el tiempo.

En esta Sección se buscará realizar una revisión de los principales sensores que podemos encontrar en un motor de aviación y que tienen una relación con el estado y la vida útil del motor, analizando los diferentes tipos de sensores, su fiabilidad y su potencial

degradación con el paso del tiempo con el fin de extrapolar un modelo de deriva que podamos aplicar a la base de datos para alcanzar modelos de predicción más próximos a su implementación.

## 5.1. Sensores en Motores de Aviación

Los motores de aviación cuentan con un conjunto de sensores que aportan diversas mediciones, útiles para comprobar el estado del motor y realizar el control del mismo. No obstante, tanto las condiciones extremas de operación del motor como la pérdida de rendimiento del motor al introducir un gran número de sensores dentro de sus componentes limita tanto la cantidad de variables tomadas como el número de sensores dispuestos.

Principalmente, podemos contemplar cinco mediciones principales empleadas para monitorizar el estado de un motor, las cuales trataremos en este punto.

1. Mediciones de presión en diversas etapas del motor.
2. Mediciones de temperatura.
3. Mediciones del flujo de combustible.
4. Mediciones del flujo másico o gasto de aire.
5. Mediciones de las velocidades de rotación de la turbomaquinaria.

Si bien podemos realizar más mediciones en un motor, estas no representan un aspecto crítico a la hora de comprobar el estado del motor y su vida útil. Consecuentemente, nos centraremos en analizar las mediciones previamente mencionadas.

### 5.1.1. Mediciones de Presión

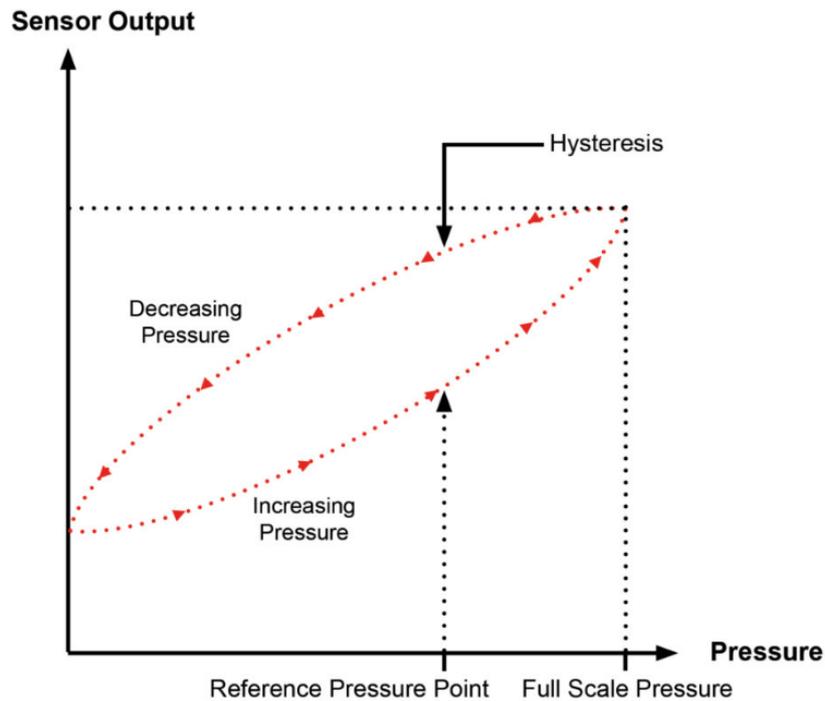
Las mediciones de presión nos permiten conocer las condiciones ambientales a las que opera el motor, comprobar el estado de motor y su eficiencia y también realizar la medición del flujo másico de aire que atraviesa el motor.

Principalmente, los manómetros y transductores constituyen los sensores de presión más extendidos. No obstante, el uso de manómetros está en desuso como consecuencia de su reducido rango de operación, de hasta dos bares de presión [16].

Por otra parte, el rango de operación de los transductores es mucho más amplio, los cuales toman el valor de la presión a través de la medición de la presión diferencial que provoca el movimiento de un diafragma. Una parte del diafragma se encuentra a presión ambiente o a otra presión conocida, mientras que la opuesta está conectada a través de una sonda al punto del cual queremos tomar el valor de la presión.

Este valor de deformación del diafragma se traduce a un voltaje y, finalmente, a un valor de presión equivalente. En condiciones idóneas podrías considerar que existe una relación lineal entre el cambio de la presión existente y el cambio de la presión tomada.

No obstante, defectos y derivas de los transductores pueden desencadenar cambios en esta curva de relación, mostrada en la Figura 5.1, produciendo una relación no lineal entre la presión real y la presión medida, desencadenando un error en la medición.



**Figura 5.1.** Efecto de la no linealidad en la curva de medición de un transductor [72].

Por otra parte, cambios en las condiciones de la cámara de presión conocida del transductor (e.g., cambio en la temperatura del aire) pueden desencadenar errores adicionales en la medición de la presión, siendo además su temperatura límite de operación de alrededor de  $170^{\circ}\text{C}$  [4].

No obstante, en los motores de aviación, los transductores se sitúan lejos del conducto principal del motor, y en ocasiones fuera del motor, siendo la sonda que lo conecta al motor la encargada de llevar la presión del mismo hasta la membrana, lo que protege al transductor y asegura la fiabilidad de las mediciones.

El uso continuado de los sensores de presión en el tiempo produce una deriva en la exactitud y precisión de las mediciones, lo que compromete la fiabilidad de los sensores. No obstante, esta deriva viene asociada a defectos en el sensor o la exposición al mismo de condiciones críticas. En el caso de motores de aviación, al estar alejado del motor, las condiciones a las que se expone reducen el efecto de la deriva a lo largo de la vida útil del sensor.

En la operación de los transductores, podemos encontrarnos errores entre el 0.1 % y el 0.5 % teniendo en consideración los diferentes errores de histéresis, no linealidad,

deriva, y ruido electrónico [16].

Adicionalmente, la calibración e inspección del estado del sensor permite reducir estos errores, llegando a alcanzar un error de exactitud del 0.25 %, lo que los convierte en sensores robustos y de gran fiabilidad.

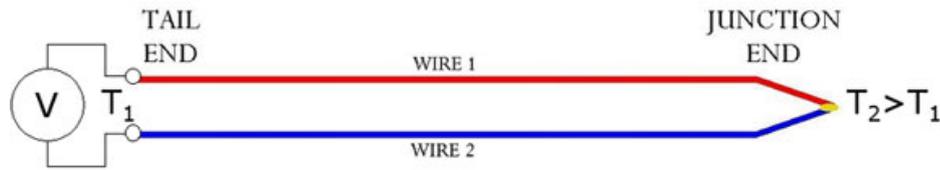
### 5.1.2. Mediciones de Temperatura

Las mediciones de temperatura tienen el fin de conocer las condiciones ambientales del flujo de aire de entrada al motor, calcular el rendimiento de cada componente del mismo, comprobar el estado e integridad de los componentes y determinar el flujo másico del motor [16].

Diferentes sensores son usados en motores de aviación con el fin de realizar la medición de la temperatura. No obstante, los más expandidos son los termopares y los termómetros de resistividad o RTDs (Resistance Thermal Detectors).

Los RTDs determinan la temperatura a partir de la medición del cambio de la resistencia de un elemento conforme sufre un cambio en su temperatura. Materiales como el platino son comúnmente empleados por su estabilidad y su buen comportamiento a la corrosión. No obstante, el rango de utilización de los RTDs no sobrepasa los 1000°C, mientras que algunos puntos del motor podemos encontrar temperaturas notablemente superiores [4]. Adicionalmente, su susceptibilidad a condiciones extremas los hace poco apropiados para ciertas mediciones del motor.

Por otra parte, el rango de utilización de los termopares puede llegar hasta los 2760°C para ciertos materiales. Estos sensores obtienen la medición de la temperatura a través de la lectura de una diferencia de potencial generada como consecuencia de una diferencia de temperatura entre dos materiales diferentes, como se ilustra en la Figura 5.2.



**Figura 5.2.** Esquema funcional de un termopar [73].

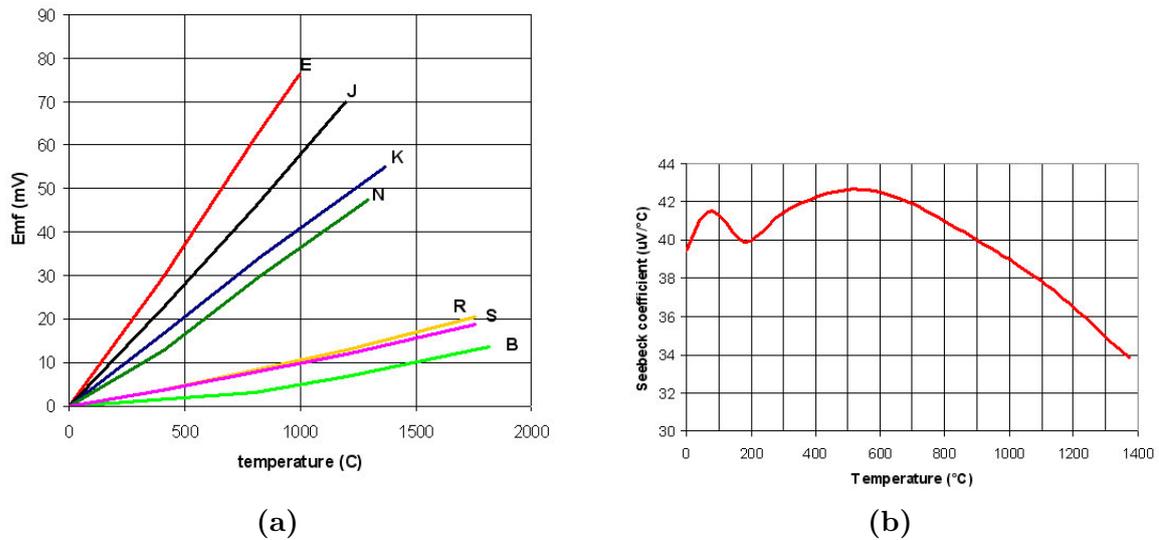
La relación entre la diferencia de potencial generada y la diferencia de temperatura causante se describe como el coeficiente de Seebeck  $S$ , el cual depende del tipo de material. Consecuentemente la expresión que relaciona la diferencia de potencial generada por un transductor equivale a [73]:

$$dV = \int_{T_1}^{T_2} (S_1 - S_2) \cdot dT \quad (5.1)$$

donde  $dV$  es la diferencia de potencial leída del transductor;  $T_1$  y  $T_2$  son las temperaturas a las que se encuentran los materiales del transductor y  $S_1$  y  $S_2$  son los coeficientes de Seebeck de los dos materiales.

A partir de esta expresión, podemos concluir que para poder obtener una medición de voltaje distinta de cero, los materiales del transductor han de tener un coeficiente de Seebeck distinto, es decir, han de ser de materiales diferentes. El coeficiente de Seebeck también indica la relación de cambio de la diferencia de potencial al producirse un cambio de temperatura y es dependiente de la temperatura.

No obstante, como se aprecia en la Figura 5.3, para la mayoría de termopares, la diferencia entre los coeficientes de Seebeck de los dos materiales que constituyen un termopar aumenta aproximadamente de forma lineal con la temperatura, aunque cada coeficiente guarde una relación no lineal con esta.

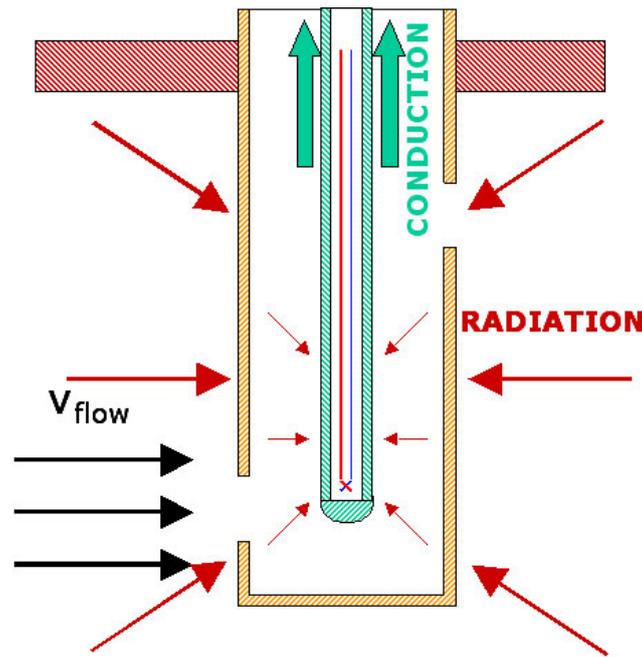


**Figura 5.3.** (a) Cambio de la diferencia de potencial con la temperatura de varios tipos de termopares; (b) Cambio en el coeficiente de Seebeck con la temperatura para un material concreto [73].

Sin embargo, siendo conocidos los materiales y los coeficientes de Seebeck de los materiales, si contamos con la diferencia de voltaje producida y controlamos la temperatura del material de referencia, podemos determinar la diferencia de temperatura producida y, finalmente, la temperatura del material deseado.

No obstante, el uso de estos sensores dentro de un motor de aviación requiere tratar con ciertas particularidades. Por una parte, la temperatura percibida por el material expuesto al flujo difiere de la temperatura total del gas, y la temperatura del termopar es la resultante de equilibrio termodinámico de los siguientes efectos, como se muestra en la Figura 5.4:

- Conducción con los componentes y la carcasa del termopar, cuyos materiales no sirven para la determinación de la temperatura.
- Radiación de las paredes del motor y de superficies en su interior.
- Convección con la capa límite alrededor del termopar.



**Figura 5.4.** Esquema del equilibrio térmico producido en un termopar dentro de un motor de aviación [73].

Adicionalmente, la medición obtenida por el termopar se corresponde con la temperatura estática del fluido, que difiere de la temperatura total, comúnmente empleada en los cálculos del ciclo y rendimiento del motor.

Sin embargo, la medición de la temperatura total dentro del termopar entraña cierta complejidad, ya que sería preciso conseguir que el gas se decelere de forma adiabática hasta el estancamiento del flujo. En cambio, dentro del termopar, el fluido se decelera pero no de forma adiabática, lo que desencadena en un error en la medición.

Todo este conjunto de errores suele agruparse bajo un coeficiente denominado como factor de recuperación  $\alpha$ , el cual se obtiene a partir de la siguiente expresión:

$$\alpha = \frac{T_2 - T}{T_0 - T} \quad (5.2)$$

donde  $T_2$  es la temperatura del material expuesto del termopar;  $T$  es la temperatura estática del flujo y  $T_0$  la temperatura total del flujo.

Como consecuencia, las mediciones de los termopares está sujeta a un error notable. Autores en la literatura como Sommerer et al. [74] realizan estudios sobre la incerti-

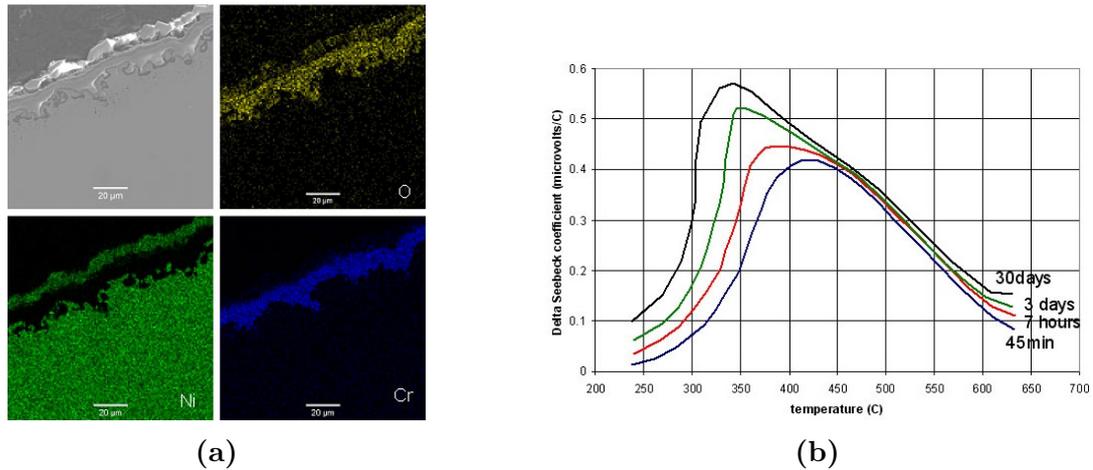
dumbre en la medición de la temperatura de los termopares en función de la ubicación y su ángulo de incidencia con el flujo, concluyendo que errores de hasta el 3.3 % del valor de la medición son producidos únicamente como consecuencia de los fenómenos previamente comentados.

No obstante, estos aspectos no representan la totalidad de las fuentes de error en la medición de los termopares. A la hora de estudiar la incertidumbre de un termopar, es necesario tener en consideración la deriva del mismo además del resto de factores previamente comentados.

La deriva de un termopar surge como consecuencia de su uso, en el que un material se encuentra sometido a un rango de temperaturas elevado. La exposición prolongada de un material a una mismo rango de temperaturas puede desencadenar que la diferencia de potencial generada por la diferencia de temperaturas equivalente cambie en el tiempo, provocando una deriva en la medición del sensor [75].

Este fenómeno surge como consecuencia de cambios superficiales en el metal que constituye el material del termopar, como la oxidación, mostrándose un ejemplo en la Figura 5.5a. Estos fenómenos surgen a raíz de la exposición al medio que se busca medir y no pueden evitarse.

Estos cambios modifican el coeficiente de Seebeck del material como muestra en la Figura 5.5b, lo que desencadenan una diferencia de potencial diferente ante una misma temperatura y, finalmente, una medición errática del valor de la temperatura.



**Figura 5.5.** (a) Oxidación de un termopar tipo K expuesto a 1200°C durante 110h vista desde un microscopio electrónico y mapas elementales de O, Ni y Cr; (b) Cambio en la curva del coeficiente de Seebeck respecto a la temperatura con el paso del tiempo [75].

Consecuentemente, la deriva de los termopares viene provocada por el uso y temperatura a la que se expone el sensor y es implícita a su uso ya que, a diferencia de las sondas de presión, el termopar se encuentra ubicado dentro del motor y como consecuencia su deriva es más severa.

Autores como Jonathan Machin et al. [52] realizan estudios experimentales del efecto de la deriva de termopares de diferentes materiales cuando se exponen a diversos intervalos de temperatura. Estos estudios formulan unas relaciones de deriva que nos permiten estimar el efecto de la deriva en la medición del sensor tras cierto tiempo de uso.

En base a este estudio, podemos concluir la importancia de tener en consideración los efectos previamente mencionados de cara a evaluar la fiabilidad de las mediciones de los sensores de temperatura, ya que sus incertidumbres son superiores respecto el resto de mediciones. Siendo necesario tener en consideración estos factores de cara a desarrollar algoritmos de predicción dependientes de todas estas mediciones.

Por otra parte, el uso de termopares resulta poco recomendado para tomar ciertas mediciones de temperatura. Etapas del motor donde el flujo alcanza temperaturas por encima de 1300 K, como la entrada a la turbina de alta presión, no suelen medirse directamente, ya que las condiciones de exposición comprometen su integridad [16].

Consecuentemente, estas temperaturas suelen estimarse a raíz de otras mediciones y por tanto están sujetas a las incertidumbres del resto de parámetros y modelos de predicción, siendo menos fiables que las mediciones directas.

### 5.1.3. Mediciones del flujo de combustible

Las mediciones del flujo de combustible sirven como indicador de la eficiencia y el consumo específico, además de estimador de las temperaturas de la cámara de combustión y turbina.

Múltiples fuentes se emplean para llevar esta medición. Es habitual contrastar la lectura de medidores volumétricos o *bulk meters*, con estimaciones del flujo esperado para la velocidad de rotación del eje. La combinación de ambas fuentes permite reducir el error asociado de forma notable, siendo los errores obtenidos por debajo del 1% del valor de la medición [16].

Si bien existe deriva en la relación entre la velocidad de rotación del eje y el flujo volumétrico de combustible, el contraste de esta estimación con la lectura del medidor de flujo volumétrico permite afianzar la exactitud de la medición.

No obstante, el flujo volumétrico de combustible suele convertirse a flujo másico, el cual tiene más valor de cara a realizar las estimaciones de eficiencia y temperatura. Esta conversión requiere conocer la densidad del combustible usado. Esto se consigue a través de ensayos en laboratorio, donde se mide la variación de la densidad del combustible al variar la temperatura.

Consecuentemente, con la medición del flujo volumétrico y su temperatura, podemos obtener una estimación de la densidad del combustible con una exactitud de alrededor del 0.1% [16]. Lo que finalmente convierte esta medición en una bien asentada.

#### 5.1.4. Mediciones del flujo másico de aire

Esta medición permite calcular la resistencia inducida y consecuentemente el empuje neto y el consumo específico del motor. También sirve el propósito de estimar la temperatura en la cámara de combustión, así como prever eventos como el surge y la capacidad de los componentes del motor.

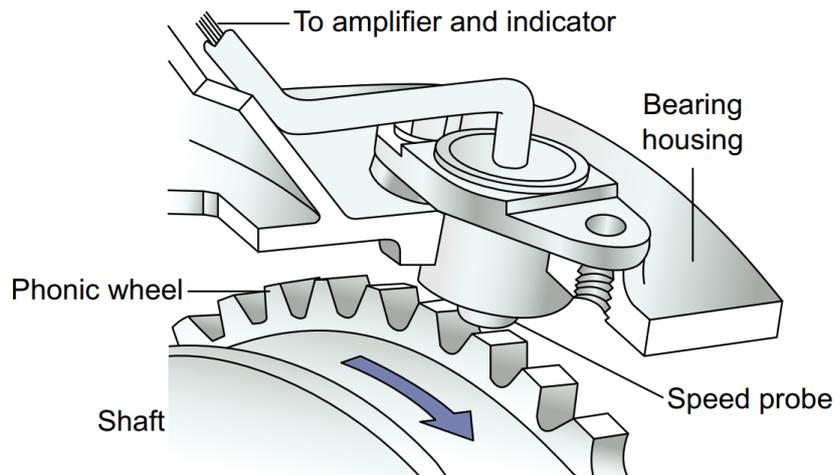
Para el cálculo de gasto másico, además de las condiciones de presión y temperatura total y estática, es necesario conocer la relación entre el área efectiva por la que circula el flujo y el área geométrica del motor. Esta relación viene comúnmente expresada a través del coeficiente de descarga o CD (Discharge Coefficient). Este coeficiente toma valor por debajo de la unidad ya que diversos efectos aerodinámicos limitan el área de paso real del motor.

El CD se calcula por ensayos experimentales y estudios con dinámica de fluidos computacional o CFD (Computational Fluid Dynamics) [16]. Cambios en el CD real durante la operación del motor, así como inexactitudes en las diferentes mediciones pueden ocasionar errores de alrededor del 0.5 % del gasto másico, por lo que podemos establecer esta medición como robusta.

#### 5.1.5. Medición de la velocidad de rotación del eje

La última medición que guarda utilidad para comprobar el estado del motor y su vida útil es la velocidad de rotación del eje. Para tomar esta medición, se emplea un sistema constituido una rueda dentada que se monta en el eje.

Un sensor electromagnético detecta el paso de los dientes de una rueda fónica, como se muestra en la Figura 5.6 generando un pulso en consecuencia. La lectura y procesado del número de pulsos permite obtener la velocidad de rotación de dicho eje.



**Figura 5.6.** Esquema de una rueda fónica para medir la velocidad de rotación de un eje [76].

Estos sistemas de medición son robustos y consiguen una gran exactitud, obteniendo mediciones muy próximas al valor real, con errores inferiores al 0.1% del valor de la medición. Consecuentemente, este parámetro constituye una medición fiable y robusta para nuestros modelos de predicción.

## 6. Base de datos y Preprocesamiento de los datos para los Algoritmos de PdM

En anteriores apartados, hemos destacado la importancia de contar con una base de datos representativa para el entrenamiento de los modelos de predicción de mantenimiento predictivo. Estos datos han de ser suficientes para permitir la predicción del RUL del motor.

Adicionalmente, estos datos han de ser homogéneos entre sí, y más importante, han de guardar esa homogeneidad con los datos que recibirá el modelo con su puesta en marcha en motores de aviación.

Consecuentemente, la búsqueda de bases de datos que consigan esta similitud representa un aspecto crucial para garantizar la viabilidad e implementabilidad de las metodologías propuestas. No obstante, en el sector aeronáutico, las bases de datos existentes sobre tiempo de vida de motores de aviación son escasas.

La base de datos más extendida en la literatura se trata de varias simulaciones del degradado de varios motores turbofan con el módulo comercial de simulación CMPASS, de la NASA. Estas bases de datos plantean diferentes modos de fallo para un número significativo de motores y contiene los suficientes sensores como para constituir un conocimiento suficiente para elaborar modelos de predicción.

No obstante, antes de ser utilizada para el entrenamiento de los modelos planteados, es necesario realizar una serie de pasos en pos de un mayor rendimiento del sistema. En esta Sección analizaremos la estructura de esta base de datos, así como los pasos previos a tu utilización para su entrenamiento, lo que se denomina en la literatura como preprocesado.

## 6.1. Base de datos CMAPSS

Esta base de datos, comúnmente denominada CMAPSS en la literatura, recoge múltiples simulaciones *run-to-failure* de motores turbofan. Estas simulaciones siguen el modelo termodinámico del un paquete de software de simulación comercial de la NASA, CMAPSS.

La base de datos está dividida en 5 subarchivos, cada uno sujeto a condiciones de operación diferentes. Para cada ciclo o vuelo de un motor, la base recoge 21 mediciones del motor de diversos sensores, los cuales se muestran en la Tabla 6.1.

**Tabla 6.1.** Sensores de la base de datos para cada instancia de medición [77].

Sensor	Descripción	Unidad
s1	Temperatura total a la entrada del fan	°R
s2	Temperatura total a la salida del compresor de baja	°R
s3	Temperatura total a la salida del compresor de alta	°R
s4	Temperatura total a la salida de la turbina de alta	°R
s5	Presión a la entrada del fan	psia
s6	Presión total en el conducto de bypass	psia
s7	Presión total a la salida del compresor de alta	psia
s8	Velocidad de rotación del fan	rpm
s9	Velocidad de rotación del eje de alta	rpm
s10	Relación de presión entre la presión total a la salida de la turbina de baja y la presión a la entrada del fan	-
s11	Presión a la salida del compresor de alta	psia
s12	Relación entre el flujo de combustible y la presión total a la salida del compresor de alta	pps/psi
s13	Velocidad del fan corregida	rpm
s14	Velocidad del eje de alta corregida	rpm
s15	Relación Bypass	-
s16	Relación entre el gasto de combustible y el gasto de aire	
s17	Entalpía del sangrado	-
s18	Setpoint velocidad del fan	rpm
s19	Setpoint velocidad del fan corregida	rpm
s20	Sangrado en la turbina de alta para refrigeración	lbm/s
s21	Sangrado en la turbina de baja para refrigeración	lbm/s

Cada motor presenta un histórico de datos desde su primera medición hasta su fallo. Cada instancia de medición tiene un valor de RUL cuantificado, es decir su eti- queta, lo que nos permite realizar el entrenamiento de nuestros modelos de Aprendizaje Supervisado.

En la Figura 6.1 podemos observar la base de datos que utilizaremos para realizar el entrenamiento de nuestros algoritmos. En las diferentes columnas o atributos tenemos el atributo *unit\_nr*, que hace referencia al motor al que corresponden los datos. Como podemos observar en esta base de datos tenemos datos pertenecientes a 100 motores similares. El atributo *time\_cycles* hace referencia al número de ciclos o número de vuelos que ha desarrollado cada motor. Los atributos *setting\_1*, *setting\_2*, *setting\_3* hacen referencia a la caracterización de distintos modos de operación de los motores. Sin embargo, en el desarrollo de nuestro problema estos atributos no son útiles por lo que en el preprocesado posterior los eliminaremos. Los atributos *s\_1*, ..., *s\_21* son las mediciones realizadas por los diferentes sensores. Finalmente, la última columna es la etiqueta o clase y define el RUL de cada motor.

[6]:

	<i>unit_nr</i>	<i>time_cycles</i>	<i>setting_1</i>	<i>setting_2</i>	<i>setting_3</i>	<i>s_1</i>	<i>s_2</i>	<i>s_3</i>	<i>s_4</i>	<i>s_5</i>	...	<i>s_13</i>	<i>s_14</i>	<i>s_15</i>	<i>s_16</i>	<i>s_17</i>	<i>s_18</i>	<i>s_19</i>	<i>s_20</i>	<i>s_21</i>	RUL
<b>0</b>	1	1	-0.0005	0.0004	100.0	518.67	642.36	1583.23	1396.84	14.62	...	2388.01	8145.32	8.4246	0.03	391	2388	100.0	39.11	23.3537	258
<b>1</b>	1	2	0.0008	-0.0003	100.0	518.67	642.50	1584.69	1396.89	14.62	...	2388.03	8152.85	8.4403	0.03	392	2388	100.0	38.99	23.4491	257
<b>2</b>	1	3	-0.0014	-0.0002	100.0	518.67	642.18	1582.35	1405.61	14.62	...	2388.00	8150.17	8.3901	0.03	391	2388	100.0	38.85	23.3669	256
<b>3</b>	1	4	-0.0020	0.0001	100.0	518.67	642.92	1585.61	1392.27	14.62	...	2388.08	8146.56	8.3878	0.03	392	2388	100.0	38.96	23.2951	255
<b>4</b>	1	5	0.0016	0.0000	100.0	518.67	641.68	1588.63	1397.65	14.62	...	2388.03	8147.80	8.3869	0.03	392	2388	100.0	39.14	23.4583	254
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
<b>24715</b>	100	148	-0.0016	-0.0003	100.0	518.67	643.78	1596.01	1424.11	14.62	...	2388.30	8138.08	8.5036	0.03	394	2388	100.0	38.44	22.9631	4
<b>24716</b>	100	149	0.0034	-0.0003	100.0	518.67	643.29	1596.38	1429.14	14.62	...	2388.28	8144.36	8.5174	0.03	395	2388	100.0	38.50	22.9746	3
<b>24717</b>	100	150	-0.0016	0.0004	100.0	518.67	643.84	1604.53	1431.41	14.62	...	2388.24	8135.95	8.5223	0.03	396	2388	100.0	38.39	23.0682	2
<b>24718</b>	100	151	-0.0023	0.0004	100.0	518.67	643.94	1597.56	1426.57	14.62	...	2388.26	8141.24	8.5148	0.03	395	2388	100.0	38.31	23.0753	1
<b>24719</b>	100	152	0.0000	0.0003	100.0	518.67	643.64	1599.04	1436.06	14.62	...	2388.24	8136.98	8.5150	0.03	396	2388	100.0	38.56	23.0847	0

24720 rows × 27 columns

**Figura 6.1.** Base de datos para el entrenamiento de las metodologías de Aprendizaje Supervisado.

No obstante, si bien el modelo de simulación de turbofan tiene en consideración diferentes causas de degradación y de fallo (e.g., fallo de compresor y turbina), estos fallos y las mediciones asociadas son simuladas, y pueden presentar diferencias respecto a estudios reales [78].

Consecuentemente, complementar esta base de datos con nuevos modos de degradación o con información que acerque este modelo más a la realidad puede ofrecer una

visión más cercana a el comportamiento del modelo de predicción con datos reales [31].

No obstante, el uso de esta base de datos para el entrenamiento del modelo requiere la realización de una serie de pasos, que procesan los datos de forma que se pueda realizar entrenamiento con los algoritmos de predicción de una forma más eficiente, sobre los cuales profundizaremos en el siguiente apartado.

## 6.2. Preprocesamiento de los Datos

Toda base de datos ha de pasar una serie de procesados para ser utilizada para el entrenamiento y predicción de un algoritmo. Gran parte de estas modificaciones comprende el trabajo de los datos, agrupando los datos en un formato y estructura que sea adecuada para su utilización por los modelos de ML.

Este trabajo de los datos se ha realizado con el lenguaje de programación Python. No obstante, a mayores de este trabajo de datos, una serie de pasos son convenientes de cara a mejorar el rendimiento y las prestaciones de los algoritmos planteados, los cuales trataremos a continuación.

### 6.2.1. Límite Superior RUL

El RUL se define como el tiempo restante de vida útil y, como tal, podría considerarse que desciende linealmente conforme el tiempo avanza. Es decir, un motor con 20 ciclos de vida restantes, 30 ciclos de uso antes, tendría 50 restantes.

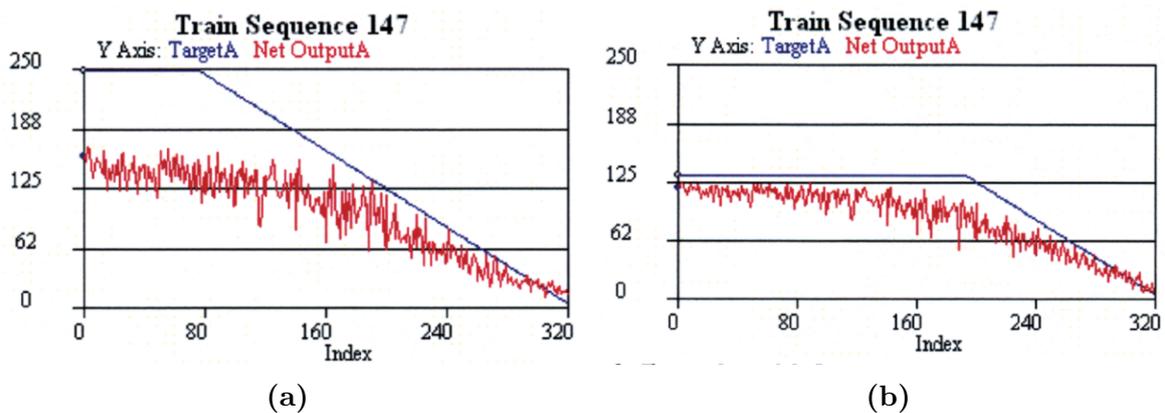
No obstante, la variación lineal del RUL se difumina cuando queremos elaborar predicciones del tiempo de vida restante conforme a ciertas observaciones. Cuando el elemento a estudiar está cerca de una avería, síntomas de su degradación pueden percibirse en los observables del mismo. Podemos discernir cuando los efectos de la avería son apreciables, la severidad de la degradación y el tiempo restante hasta el fallo.

No obstante, cuando un elemento está en perfecto estado, no hay síntomas apreciables de degradación en los observables, lo que nos impide realizar una estimación del

tiempo de vida restante sin mayor información que una única instancia temporal de observables.

Consecuentemente, de cara a afrontar esta frontera en algoritmos que emplean una única instancia para la predicción, en la literatura se plantea establecer un valor máximo de RUL, bajo el cual se considera que el elemento a estudiar está en buenas condiciones [79].

En el campo del mantenimiento predictivo en motores de aviación, la literatura plantea un valor de RUL limite de alrededor de 125 ciclos como una buena medida para contener el error de predicción cuando el motor se encuentra en buen estado [80], como muestra la Figura 6.2.



**Figura 6.2.** Comparativa modelo de predicción al aplicar o no un límite al RUL de motores de aviación; (a) muestra la estimación cuando el RUL sigue un modelo lineal mientras que (b) muestra el cambio en la estimación cuando se establece un valor máximo del RUL, lo que mejora la exactitud del método [80].

En base a este análisis, se ha aplicado este recorte del RUL de aquellas instancias para las que el RUL asociado supere la cifra de 125 ciclos. Esto nos permite centrarnos en mejorar la exactitud de las metodologías de predicción cuando evalúan la fase final de degradación, la cual tiene mayor importancia.

### 6.2.2. Normalización

El proceso de normalización de los datos consiste en transformar los valores numéricos de la base de datos de forma que todos ellos queden comprendidos en el rango  $[0,1]$  [81]. Esta normalización se realiza mediante la siguiente expresión:

$$X_i^N = \left\{ \frac{X_{i,j} - \min(X_i)}{\max(X_i) - \min(X_i)}, \forall \in 1, \dots, n \right\} \quad (6.1)$$

Donde  $X_i$  es cada atributo (columna de la base de datos),  $X_i^N$  es su normalización y  $j$  cada una de las filas de la tabla de datos.

La importancia del desarrollo de esta normalización reside en la homogeneidad de la importancia de los datos independientemente de su valor numérico [81]. Esto tiene vital importancia ya que los algoritmos no comprenden el sentido físico de cada una de las variables de la base de datos, por lo que un número mayor es entendido por el algoritmo como más importante, cuando no tendría por qué ser cierta esta afirmación.

Este caso lo podemos encontrar en nuestra base de datos, donde podemos observar datos de temperatura de 1500 °R y datos de relaciones de presión de 13. Al tener las variables normalizadas se representa más claramente el rango de importancia, ya que un cambio porcentual de un 10 % en cada una de estas mediciones, al estar normalizadas, es igual de importante en ambas. Sin embargo, este cambio en valores absolutos produciría un aumento en la temperatura de 150 unidades mientras que en la relación de presiones este aumento sería de 1.3, y por tanto para el algoritmo tendrá mucho más peso el cambio en la temperatura que en la relación de presiones cuando realmente el porcentaje de aumento y por tanto la importancia de este es igual en ambas variables.

### 6.2.3. División de los Datos

En todos los algoritmos de Aprendizaje Supervisado es imprescindible realizar la división de los datos disponibles en dos subgrupos. El primero de ellos será el que se utilizará para entrenar el modelo, comúnmente conocido como *train*, y el segundo será el que se utilizará para comprobar el rendimiento del algoritmo después de haber sido

entrenado, comúnmente denominado *test*.

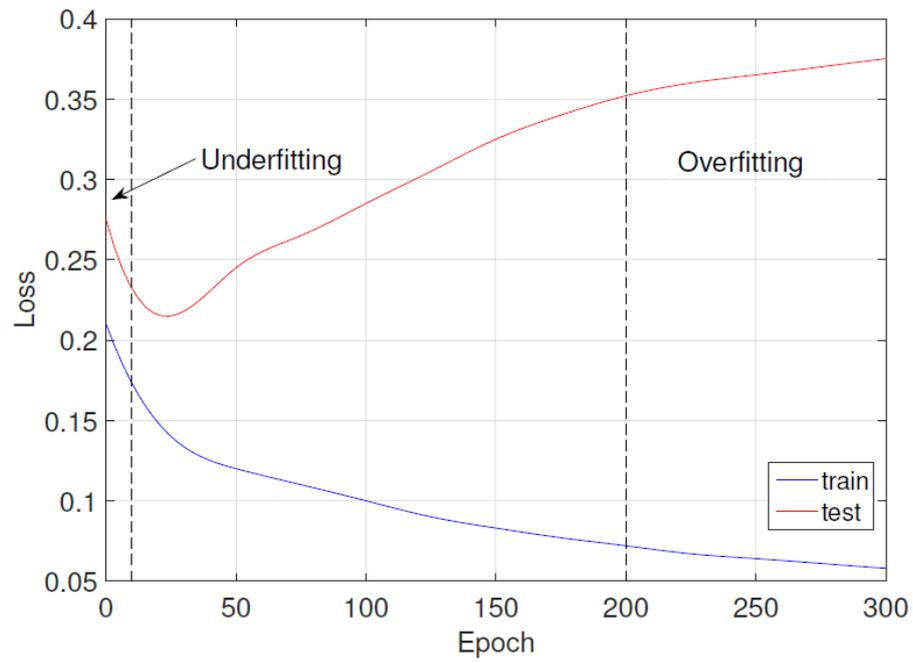
Además de ello será necesario realizar otro subgrupo dentro del conjunto de datos que se utiliza para entrenar el modelo. Este conjunto de datos es comúnmente un 10 % o 20 % de los datos del *train* y se denomina conjunto de validación.

En la Tabla 8.1 de la Sección 8 se pueden observar los porcentajes de datos utilizados para cada uno de los subgrupos.

El conjunto de validación es de gran importancia ya que permite evaluar el proceso de aprendizaje de manera que permite comprobar si hay problemas de sobreajuste (*overfitting*) o subajuste (*underfitting*) [82].

Estos dos problemas podemos localizarlos estudiando la relación que existe entre los valores de error obtenidos en el conjunto de entrenamiento, conocidos como errores de entrenamiento, respecto a los valores de error obtenidos con el conjunto de test, conocidos como errores de generalización. En el caso de subajuste tanto los errores obtenidos por el conjunto de entrenamiento como de test serán altos. Esto ocurre debido a que el modelo está poco entrenado y no es capaz de crear relaciones entre las instancias. Por tanto no es capaz de clasificar o predecir las etiquetas del conjunto de entrenamiento, por lo que finalmente tampoco será capaz de hacerlo con el conjunto de test y por esta razón, tanto los errores de entrenamiento como de generalización son altos.

En cambio podemos distinguir el sobreajuste cuando al comparar los errores de entrenamiento y de generalización observamos que el error de entrenamiento disminuye mientras que el error de generalización aumenta mucho. Esto ocurre debido al sobreentrenamiento del algoritmo que en lugar de aprender a clasificar o predecir las instancias lo que hace es memorizar las instancias del entrenamiento. Por esta razón el error de entrenamiento disminuye de forma tan notable, sin embargo, al introducir las instancias del test como estas son diferentes a las de entrenamiento cometerá un error mucho mayor en la predicción.



**Figura 6.3.** Representación gráfica de Overfitting y Underfitting a lo largo del entrenamiento de un algoritmo [82].

## 7. Desarrollo de un modelo de Incertidumbre y Deriva de los sensores para el Entrenamiento de los Algoritmos de Mantenimiento Predictivo

En el anterior apartado hemos descrito la base de datos que emplearemos para desarrollar nuestro algoritmo de predicción. Esta base de datos busca equiparar las condiciones reales de su aplicación, indicando en cada instancia de datos las principales mediciones que podemos encontrar en un motor de aviación, habiendo descrito en la Sección 5 los principales sensores utilizados para este fin.

No obstante, esta base de datos, al ser exportada de un entorno de simulación, no tiene en consideración las diferentes incertidumbres y derivas de los sensores que tomarían esas mediciones en un motor real. Esta consideración se traduce en un cambio en la homogeneidad de los datos, y por lo tanto puede comprometer la integridad de los modelos empleados para el mantenimiento predictivo, ya que estos requieren entrenarse con datos equivalentes a los que percibirán en su puesta en marcha.

A raíz de esto, buscando desarrollar un modelo de predicción más cercano al entorno de operación de un motor, en este Trabajo de Fin de Máster, por primera vez en la literatura, se plantea modificar esta base de datos incorporando las incertidumbres y derivas de los sensores estudiados en la Sección 5 al conjunto de mediciones, buscando así lograr un conjunto de datos más próximo a las condiciones de operación esperables en su puesta en práctica.

Para ello, se ha clasificado las 21 mediciones existentes en la base de datos CMAPSS, mostrados en la Tabla 6.1 en función del sensor o conjunto de sensores que resultan en esa medición. En base a esta clasificación, partiendo de los valores de incertidumbre, deriva y otras fuentes de error que hemos analizado en la Sección 5 para cada sensor, se plantea desarrollar un nuevo modelo de mediciones sujeto a estas fuentes de error experimentales.

En la Tabla 7.1 se expone la clasificación realizada, así como los valores porcentuales de incertidumbre introducidos a cada medición. Las incertidumbres de las mediciones

que componen múltiples medidas de sensores del mismo o diferente tipo se han calculado siguiendo las bases de composición de incertidumbres.

**Tabla 7.1.** Clasificación de las mediciones de la base de datos CMAPSS y utilización de los valores de incertidumbre para cada tipo de medición, siguiendo los valores asociados a los diferentes sensores más utilizados para cada medición.

Sensor	Origen de la Medición	Incertidumbre
s1	Temperatura	3.3 % + $\lambda(T, \text{ciclos})$
s2	Temperatura	3.3 % + $\lambda(T, \text{ciclos})$
s3	Temperatura	3.3 % + $\lambda(T, \text{ciclos})$
s4	Temperatura	3.3 % + $\lambda(T, \text{ciclos})$
s5	Presión	0.25 %
s6	Presión	0.25 %
s7	Presión	0.25 %
s8	Velocidad de Rotación	0.1 %
s9	Velocidad de Rotación	0.1 %
s10	Presión, Presión <sup>-1</sup>	0.5 %
s11	Presión	0.25 %
s12	Flujo Combustible, Presión <sup>-1</sup>	0.6 %
s13	Velocidad de Rotación	0.1 %
s14	Velocidad de Rotación	0.1 %
s15	Gasto Aire, Gasto Aire <sup>-1</sup>	1 %
s16	Flujo Combustible, Gasto Aire <sup>-1</sup>	0.6 %
s17	Temperatura	3.3 % + $\lambda(T, \text{ciclos})$
s18	Velocidad de Rotación	0.1 %
s19	Velocidad de Rotación	0.1 %
s20	Gasto de Aire	0.5 %
s21	Gasto de Aire	0.5 %

La deriva de las mediciones provenientes de la temperatura,  $\lambda$  ha sido la única deriva considerada como fórmula separada de la incertidumbre general. Esto se debe a que, según se comentó en el anterior apartado, los termopares son los equipos más expuestos a las condiciones de operación del motor, y por lo tanto son los que más sufren una degradación en su funcionamiento. Podemos estimar la deriva de un termopar a partir de la siguiente expresión:

$$\lambda(T, \text{ciclos}) = DR_T \cdot \text{ciclos} \cdot t_{\text{ciclo}} \quad (7.1)$$

donde  $T$  es la temperatura del flujo donde se encuentra el termopar, la cual se aproxima a la medición de temperatura tomada;  $DR$  (Drift Rate) es la relación de deriva, dependiente del tipo de termopar y temperatura de exposición,  $\text{ciclos}$  es el número de vuelos que ha realizado el motor, información con la que contamos en la base de datos y  $t_{\text{ciclo}}$  es el tiempo de vuelo por ciclo, estimado como 2 horas a partir del tiempo de vuelo promedio y el tiempo de rodaje por vuelo [83].

Para estimar el DR de cada medición, se ha empleado unos datos experimentales de deriva para los diferentes tipos de termopar para diversas condiciones [52]. Estudiando el termopar tipo K, uno de los más empleados en la aviación, obtenemos los siguientes intervalos de DR para las condiciones expuestas en la Tabla 7.2.

**Tabla 7.2.** Relación de deriva para los diferentes rangos de exposición de un termopar tipo K [52].

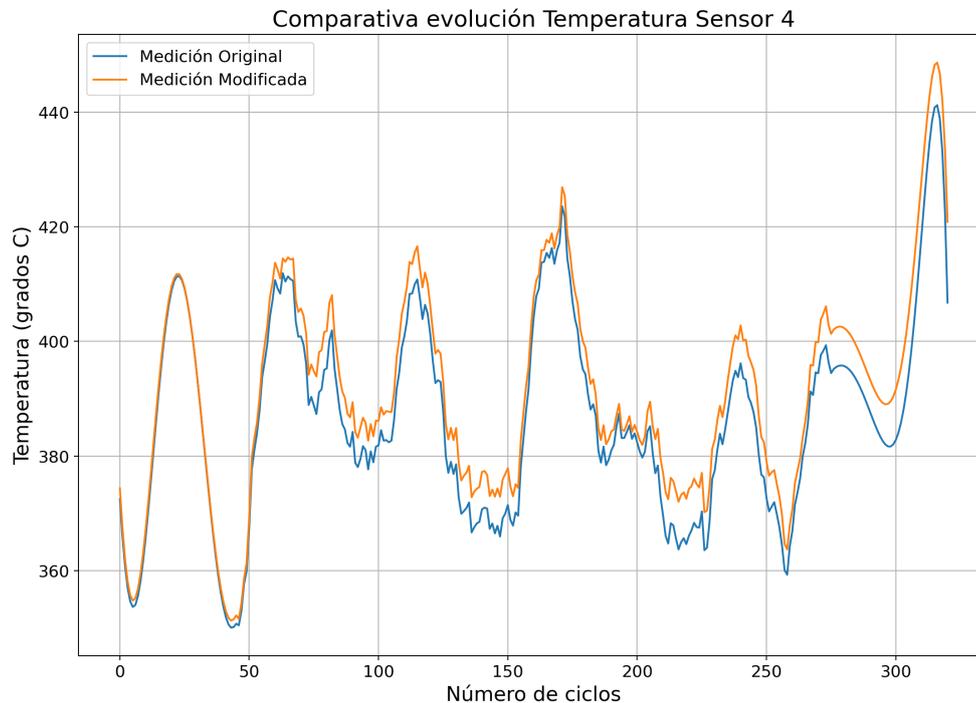
Rango de Exposición ( $^{\circ}C$ )	$DR_T (^{\circ}C \cdot h^{-1})$
$600 < T \leq 700$	0.0116
$700 < T \leq 800$	0.00363
$1000 < T \leq 1200$	-0.0055
$T \geq 1250$	0.0116

Cabe destacar que, a fin de estudiar estos intervalos de deriva de los termopares, se ha realizado el cambio de grados Rankine, unidad de temperatura de la base de datos, a grados Celsius, siguiendo la siguiente expresión de conversión:

$$T(^{\circ}C) = \frac{T(^{\circ}R) - 491.67}{1.8} \quad (7.2)$$

A partir de estos valores, se ha aplicado un algoritmo de corrección, que introduce a cada medida un error aleatorio proporcional a la medición según los valores mostrados en la Tabla 7.1. A mayores, en el caso de las mediciones dependientes de los sensores de temperatura, se añade la componente de deriva en función de la temperatura a la

que se corresponde esa medición. En la Figura 7.1 se puede apreciar la introducción de las dos componentes del error para la medición trazada.



**Figura 7.1.** Evolución del error de un sensor de la base de datos con y sin las modificaciones planteadas. Ambas curvas han sido suavizadas con un filtro para poder apreciar el efecto de la deriva del sensor.

En la Figura 7.1, se puede apreciar la deriva del termopar, la cual aumenta conforme aumenta el número de ciclos, ya que en ese intervalo de temperatura, la deriva causa un aumento en la medición, como se muestra en la Tabla 7.2. Cabe mencionar que, al introducir curvas suavizadas, el efecto del error proveniente de una mayor incertidumbre introducida resulta menos apreciable, no obstante, podemos comprobar su existencia al notar fluctuaciones entre la separación entre ambas curvas, la cual se debe a la mayor componente de error de la medición modificada.

Este modelo propuesto, novedoso en la literatura, supone dar un paso hacia la homogeneización de los datos de entrenamiento con los posibles datos de puesta a prueba, ya que mediciones adicionales sobre el comportamiento de los sensores son tenidas en cuenta a la hora de construir el modelo de entrenamiento, de forma que los valores simulados se aproximen al comportamiento esperado del motor.

Tras la aplicación de esta metodología a todos los datos, se plantea la implementación y prueba de las diferentes metodologías estudiadas, en pos de encontrar la metodología más fiable, aunque también la más aplicable para el contexto del mantenimiento predictivo en motores de aviación, lo cual discutiremos en el siguiente punto.

## 8. Resultados

En esta Sección finalmente se implementan las diferentes metodologías analizadas durante la Sección 4 sobre la base de datos previamente analizada. En la Tabla 8.1 se expone la configuración de hiperparámetros seguida para la ejecución y prueba de cada metodología analizada en los cálculos mostrados.

**Tabla 8.1.** Lista de los hiperparámetros ajustados experimentalmente de cada metodología utilizada para los cálculos de esta Sección.

Metodología	Parámetro	Elección
Regresión Lineal	Porcentaje train	67 %
	Porcentaje test <sup>a</sup>	33 %
Random Forest	Porcentaje train	67 %
	Porcentaje test <sup>a</sup>	33 %
	Número de Árboles	20
	Metodología de Maximización	Sqrt
	Semilla	42
Red Neuronal Artificial	Porcentaje train	53.6 %
	Porcentaje validación	13.4 %
	Porcentaje test <sup>a</sup>	33 %
	Número de Capas Ocultas	3
	Número de Neuronas Capa de Entrada	21
	Número de Neuronas Capa Oculta 1	128
	Número de Neuronas Capa Oculta 2	64
	Número de Neuronas Capa Oculta 3	8
	Número de Neuronas Capa de Salida	1
Función de Activación	ReLU	
Optimizador	Adam	
Función de Pérdidas	RMSE	
Número de Épocas	60	

<sup>a</sup> Porcentaje impuesto por la estructura de la base de datos tomada.

A partir de estas configuraciones, se han entrenado diferentes modelos para predecir el RUL de diferentes motores en la base de datos. A fin de realizar una comparativa

entre paradigmas, se ha entrenado y evaluado el comportamiento tanto en la base de datos original como en la modificada con los ruidos y derivas específicos de los sensores tratados en la Sección 5.

En la Tabla 8.2 se muestra los resultados de predicción con los datos de test y train con las diferentes metodologías tras finalizar su entrenamiento para ambos casos.

**Tabla 8.2.** Resultados de la evaluación del RMSE en la estimación del RUL para cada metodología sobre los datos existentes en cada caso de estudio. Unidades en ciclos del motor.

Metodología	CMAPSS Original		CMAPSS Modificado	
	RMSE Train	RMSE Test	RMSE Train	RMSE Test
Regresión Lineal	19.33	17.96	22.22	20.64
Random Forest	15.87	14.85	18.49	16.86
Red Neuronal	20.65	17.51	30.19	25.77

Sobre esta tabla de resultados podemos extraer múltiples conclusiones. Los valores asociados a la base CMAPSS original, los cuales son parejos a los valores encontrados por la literatura [31], son superiores a los obtenidos con la base de datos modificada.

Este hecho nos refleja el impacto de introducir desviaciones en las mediciones de los sensores. Y si bien las prestaciones del modelo son inferiores, de realizarse un estudio en una base de datos más realista, el modelo que introduce la degradación podría guardar una relación más próxima con el conjunto de mediciones reales. No obstante, también sería necesario el estudio del resto de aspectos que pueden afectar en las desviación de las mediciones reales.

Además, debido a que se produce mayor variación entre las instancias de motores con la misma etiqueta de RUL, todos los algoritmos tienen mayores dificultades para asociar los patrones, y por lo tanto podemos observar en la Tabla 8.2 que todos los algoritmos presentan mayor RMSE en comparación con los modelos originales.

Por otra parte, el modelo de Random Forest obtiene las mejores métricas en ambos casos de estudio, mientras que la Red Neuronal obtiene resultados notablemente lejanos en la modificada. Esto no refleja que la Red Neuronal no sea una metodología válida

para el caso planteado, con un ajuste de hiperparámetros más profundo y un mayor número de datos para el aprendizaje la red neuronal podría sobrepasar al resto de modelos planteados.

También es necesario destacar que la ANN es una metodología más compleja que la Random Forest ya que intervienen gran cantidad de parámetros en su desarrollo. Por esta razón los tiempos de entrenamiento y predicción mayores que en el caso de uso de las otras métricas. Por ello sería necesario un estudio de la viabilidad de aplicación en situaciones reales donde sea necesaria gran velocidad de predicción.

No obstante, este ajuste y la ampliación de la base de datos no son el principal foco dentro de nuestro campo de conocimiento. La baja disponibilidad de datos dificulta el desarrollo de metodologías altamente dependientes de datos como son las desarrolladas en ML y por lo tanto en este Trabajo de Fin de Máster. Adicionalmente, estos modelos son particularmente susceptibles a cambios en la homogeneidad de los datos, como podemos comprobar por el aumento del error al trasladarse a la base de datos modificada.

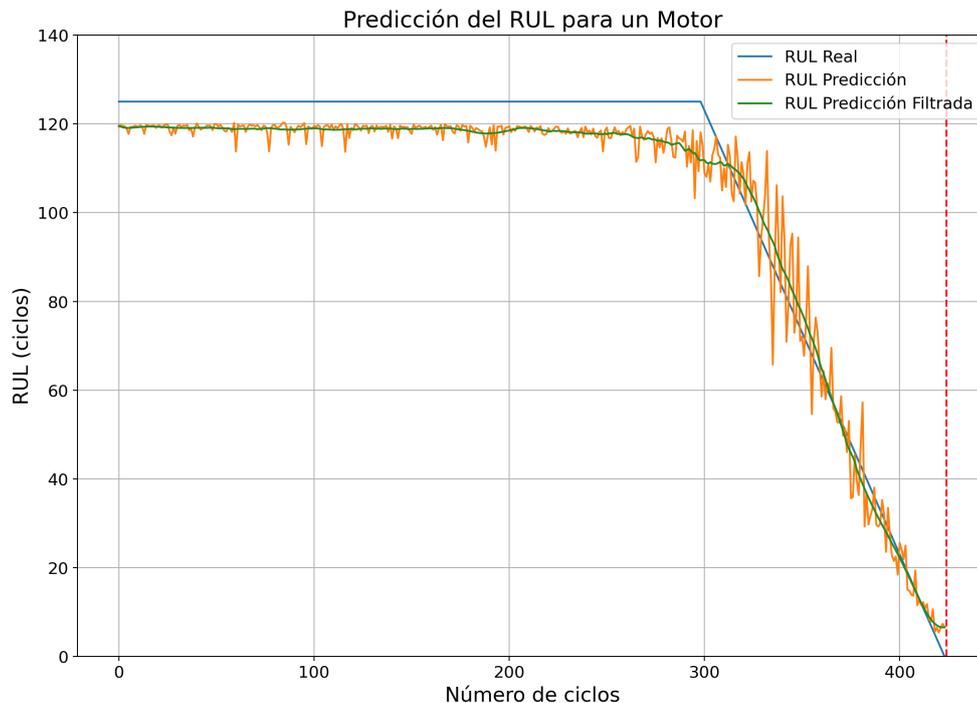
También es importante tener en cuenta que en nuestro sector existen diferentes tipos de aeronaves, tipos de motores y tipos de operaciones diferentes. Por lo tanto, teniendo en cuenta que estos modelos son altamente dependientes de los datos de entrenamiento sería necesario tener datos históricos de cada tipo diferente para así poder entrenar el modelo para cada aplicación concreta, con su consecuente ajuste de hiperparámetros, lo que alejaría estos modelos de su pronta aplicación. Este aspecto es de vital importancia ya que si alimentamos el modelo con datos que están muy alejados de los datos de entrenamiento obtendremos en su mayoría predicciones erráticas que no se ajustarían a la realidad.

No obstante, es preciso remarcar un aspecto de gran importancia en los resultados mostrados. Las metodologías, al entrenarse, realizan una predicción de un RUL a partir de una única instancia de datos. Esto quiere decir que bajo su estricto entrenamiento y uso, estas metodologías no tienen en consideración el histórico de datos para el motor al cual pertenecen las mediciones. Esto se trata de un aspecto crítico, ya que estamos perdiendo la información que nos aporta la evolución de mediciones para un mismo

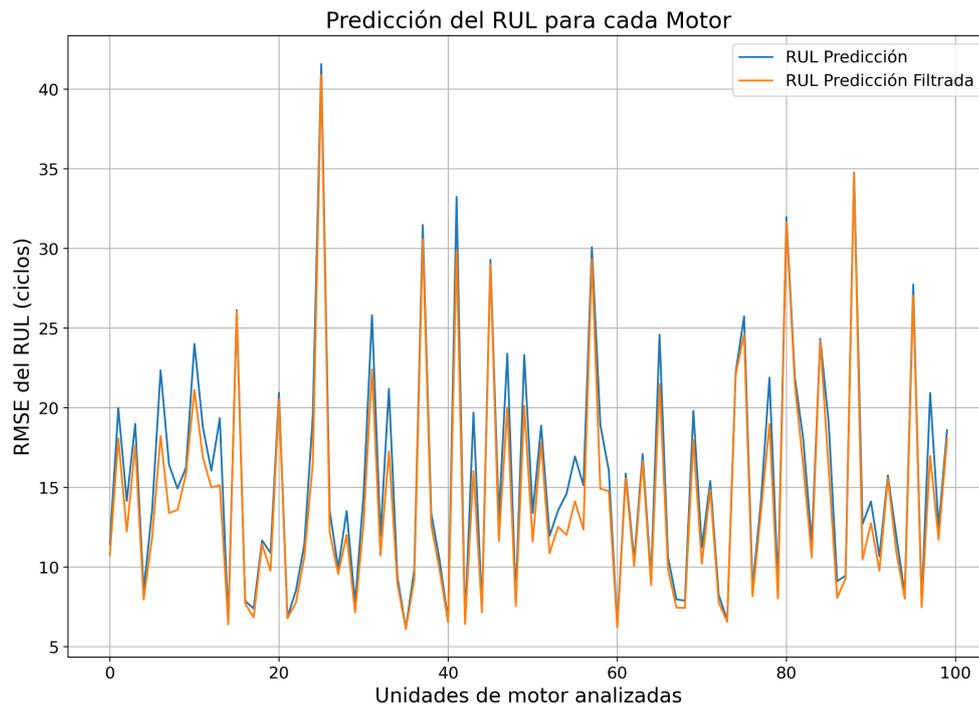
motor.

Consecuentemente, en este Trabajo de Fin de Máster se propone un análisis adicional para introducir el conocimiento de este histórico de datos en la predicción, empleando para ello los modelos entrenados. Este estudio se fundamenta en la aplicación del filtro de Savitzky-Golay para el suavizado de las estimaciones del RUL para un mismo motor [84]. Esta curva, representada en la Figura 8.1, nos acerca más al RUL real que las mediciones singulares de nuestro modelo, lo que reduce el error de predicción.

En la Figura 8.2 se representa, para cada motor, el RMSE entre la curva del RUL real de ese motor y las curvas de RUL estimado y filtrado. Siendo cada motor un punto, la gráfica nos ofrece una comparativa del error obtenido por ambos enfoques.



**Figura 8.1.** Comparativa del RUL real, la estimación del RUL y la estimación del RUL filtrada para un motor de la base de datos.



**Figura 8.2.** Comparativa del RMSE generado entre las curvas del RUL y del RUL estimado y filtrado por cada motor. La curva azul, indicativa del RUL estimado, tiene un valor promedio de 15.67 ciclos, mientras que la curva naranja, indicativa del RUL suavizado, tiene un promedio inferior, de valor 14.42 ciclos.

Si bien podemos observar cierta variabilidad, podemos discernir que el RUL suavizado alcanza menores cotas de error en la mayoría de los motores que el RUL estimado, siendo además su valor promedio inferior.

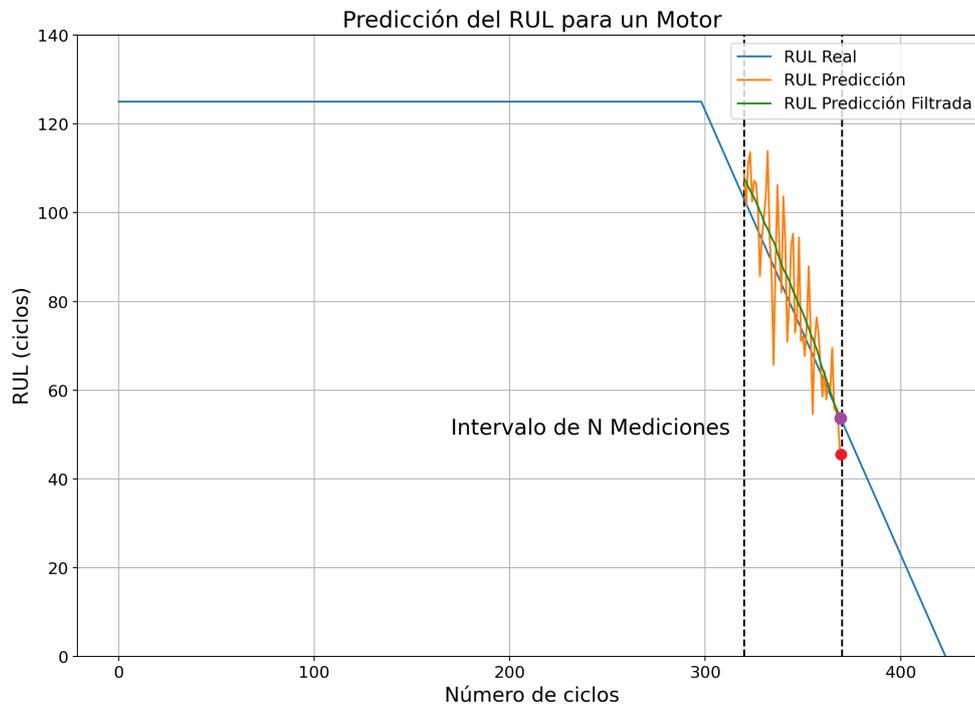
No obstante, los resultados que podemos extrapolar de la Figura 8.2 no reflejan en su totalidad la mejoría de la utilización de la curva filtrada. Si observamos la Figura 8.1, podemos ver que los mayores niveles de error de la curva filtrada ocurren cuando el RUL se encuentra en su valor máximo, como es común en la literatura [80].

En estos casos, pequeños errores en la estimación del RUL no resultan problemáticos, ya que el fallo no es próximo. Por otra parte, errores en la estimación del RUL cuando la avería está cercana son más críticos, ya que podrían dar una falsa sensación de seguridad. No obstante, es en este tramo final de degradación donde la curva suavizada obtiene una mayor exactitud, ya que tiene en consideración el histórico completo de las estimaciones.

Para comprobar la dependencia de la metodología del histórico de datos, así como

su mejoría conforme aumenta el número de mediciones, se ha diseñado un algoritmo de evaluación del RUL. Este algoritmo recorre las mediciones de los motores de la base de datos y, por cada motor, realiza un segmento de corte que engloba un número concreto de mediciones ubicadas en la recta final de degradación del motor, tal y como muestra la Figura 8.3.

Consecuentemente, se ha aplicado el algoritmo a fin de obtener el error en el RUL actual en relación con el RUL estimado y el RUL estimado filtrado (i.e., círculos rojo y morado en la Figura 8.3) para cada motor de la base de datos. El error se ha medido empleado el RMSE entre los puntos. En la Tabla 8.3 se recogen los resultados de este análisis para cada motor al variar el número  $N$  de histórico de mediciones.



**Figura 8.3.** Esquema del funcionamiento del algoritmo de evaluación para el RUL de un segmento de mediciones.

**Tabla 8.3.** Tabla comparativa de la estimación actual del RUL dado un histórico de  $N$  mediciones.

Mediciones	Metodología	RMSE (ciclos)			$\sigma_{RMSE}$
		Media	Max	Min	
$N = 5$	RUL Estimado	18.01	56.06	1.64	11.48
	RUL Filtrado	16.13	54.48	1.44	11.28
$N = 15$	RUL Estimado	18.80	55.32	2.96	12.12
	RUL Filtrado	16.76	54.74	1.43	13.07
$N = 40$	RUL Estimado	22.26	63.27	2.58	14.51
	RUL Filtrado	20.03	63.27	2.58	14.50
$N = 100$	RUL Estimado	19.92	58.69	2.34	13.92
	RUL Filtrado	12.07	30.9	1.42	9.24

Podemos comprobar que la predicción basada en trazar el filtrado del histórico de estimaciones previas otorga mejores resultados que las estimaciones independientes, lo que verifica el interés de considerar el histórico de datos para cada motor. Cabe mencionar, que las mediciones con intervalos pequeños de datos conllevan menos fiabilidad, ya que, en función de donde se ocasione el final del intervalo obtendremos mejores o peores métricas.

Sin embargo, para un número de mediciones significativo para la base de datos con la que contamos, la predicción por suavizado supera significativamente a la estimación del modelo, la cual no tiene en consideración el histórico de datos. La incorporación de un mayor número de datos permitiría reducir aún más el error asociado, logrando por lo tanto mejores resultados.

Finalmente, los resultados obtenidos validan las metodologías estudiadas y las hipótesis planteadas a lo largo esta memoria. Adicionalmente, los análisis y la metodología propuesta supone una mejoría de los modelos de estimación, al tener en cuenta el histórico de datos de cada motor para la predicción del tiempo de vida útil, obteniendo resultados que lo validan. Por lo tanto, se concluye que los resultados obtenidos cumplen con el propósito de estudiar y desarrollar un sistema de predicción de averías para motores de aeronaves, cumpliendo por tanto con los objetivos de este

Trabajo de Fin de Máster.

## 9. Conclusiones

En este Trabajo de Fin de Máster se ha realizado un estudio de las diferentes estrategias de planificación de mantenimiento y su aplicación a motores de aviación. También hemos estudiado diferentes metodologías de Aprendizaje Supervisado englobadas dentro de la disciplina de la inteligencia artificial. Hemos aplicado estas metodologías a la base de datos CMAPSS desarrollada por la NASA donde se recogen datos relativos a la operación simulada de motores turbofan, de forma que los algoritmos predigan la vida útil restante de los motores.

Debido a que los datos de la base de datos no se han obtenido experimentalmente, si no que se han desarrollado a partir de un modelo donde no se tienen en cuenta las incertidumbres ni la degradación sufrida por los sensores, se ha propuesto en este Trabajo de Fin de Máster un modelo que simule estos aspectos, ya que no se ha encontrado nada de esta índole en la revisión de la literatura. Este modelo de degradación se ha aplicado a los datos y se han entrenado los algoritmos con los datos originales y modificados para poder realizar la comparativa sobre las métricas obtenidas con ambos.

A la luz de los resultados obtenidos en nuestro caso de estudio y con los hiperparámetros utilizados obtenemos que la metodología de Random Forest es con la que menor RMSE obtenemos tanto con el dataset original como con el modificado.

Los resultados obtenidos teniendo en cuenta el modelo de degradación tienen mayor RMSE lo cual se fundamenta en la mayor variabilidad de los datos respecto a la etiqueta asociada y por tanto el algoritmo tiene mayores dificultades a la hora de realizar la predicción. Sin embargo, no es un objetivo de este Trabajo de Fin de Máster obtener el menor error posible mediante el filtrado de los datos, si no realizar el estudio que más se aproxime a la operación real del turbofan de forma que estos resultados puedan ser lo más escalables a la realidad. La propuesta que se ha realizado para acercar un poco este planteamiento simulado a la realidad ha sido el modelo de degradación de los sensores.

No obstante, los métodos de Aprendizaje Supervisado son altamente dependientes tanto de la naturaleza de la base de datos como del número de instancias que posea esta

por lo que no significa que las Redes Neuronales y la Regresión Lineal posean peores rendimientos en todos los casos de aplicación al mantenimiento predictivo de motores de aviación. Esto significa que se tendría que realizar un estudio más exhaustivo de cada caso de aplicación, ya que existe gran variedad de motores en la actualidad, por lo que la escalabilidad al sector aeronáutico actual puede no ser cercana.

También cabe destacar que por la naturaleza de la base de datos así como de los algoritmos empleados no se tiene en cuenta el histórico de datos que tenemos para cada motor. Este es un aspecto que sí afecta en la realidad en el desgaste y operación. Por ello, se propone un estudio de la evolución del RUL para un motor teniendo en cuenta diferente número de ciclos. Podemos observar que el RMSE disminuye al aumentar el número de ciclos estudiados, lo que refuerza la dependencia de esta predicción con el histórico de datos.

Durante el desarrollo de este Trabajo de Fin de Máster se han satisfecho los objetivos planteados en la Sección 2 y podemos extraer las siguientes conclusiones:

- La aplicación de metodologías de inteligencia artificial en el campo del mantenimiento predictivo puede suponer grandes avances en el ámbito de la seguridad así como en términos económicos y de disponibilidad de las aeronaves al realizar las tareas de mantenimiento solo en los momentos en los que estas son realmente necesarias.
- Mediante medidas de sensores a lo largo de un turbofan podemos predecir el RUL de los motores recogidos en la base de datos CMAPSS. Hemos propuesto un modelo de degradación de los sensores en base a datos obtenidos en la literatura, de forma que los resultados obtenidos puedan asemejarse en mayor medida a los datos que podríamos medir durante la operación de un turbofan. No obstante, este es solo uno de los muchos aspectos que pueden producir desviaciones en las mediciones, por lo que no podemos decir que este modelo se adecúe completamente a la realidad.
- Los resultados obtenidos suponen un estudio muy interesante, sin embargo para su aplicación al sector aeronáutico actual es necesario el desarrollo de nuevas

bases de datos que permitan a los algoritmos entrenarse en mayor número de condiciones de operación, mayor variedad de tipos de motor, con mayor número de tomas de datos durante cada vuelo para tener en consideración fases como el despegue y el aterrizaje... etc. Por ello es un campo en el que todavía es necesario realizar grandes tareas de investigación y pruebas antes de ser aplicado a la realidad.

El campo de desarrollo de la inteligencia artificial es muy amplio y en este Trabajo de Fin de Máster hemos estudiado las más utilizadas en la literatura. Sin embargo, como líneas futuras podría realizarse un estudio mayor de otras metodologías así como un mayor estudio de los hiperparámetros utilizados, no obstante este aspecto se encuentra fuera de los objetivos principales de este Trabajo de Fin de Máster.

Otro aspecto que se podría estudiar es el uso de el algoritmo basado en Series Temporales para el estudio del RUL teniendo en cuenta el histórico de datos.

Cabe destacar que como se puede ver en la Sección 8 los mayores errores se concentran en los momentos iniciales debido a que es mucho más compleja la estimación de RUL cuando los motores todavía no presentan evidencias de desgaste. En un futuro se podría estudiar la posibilidad de realizar un filtrado para eliminar estos primeros datos, y por lo tanto estudiar la parte final, cuando vemos que los algoritmos presentan menores errores de estimación. No obstante, en esta ocasión se ha aplicado el recorte del RUL a 125 ciclos en base a la literatura y no se ha realizado esta filtración debido al bajo número de instancias que tendríamos para entrenar y comprobar los modelos.

De forma análoga sería muy interesante desde el punto de vista del mantenimiento hacer el estudio de qué componente es el que produciría el fallo. Sin embargo, dada la naturaleza de la base de datos, donde no tenemos esta etiqueta, no podríamos realizar técnicas de Aprendizaje Supervisado y no se ha encontrado ninguna base de datos en la literatura que nos permitiera hacer este estudio. No obstante, se podrían llegar a aplicar técnicas de Aprendizaje No Supervisado que permitan clasificar los motores según sus mediciones, en grupos según el potencial componente que podría fallar.

## Referencias

- [1] M. Loong, *The essentials of airplane maintenance*. Partridge Publishing Singapore, 2015.
- [2] R. Langton and B. MacIsaac, *Gas turbine propulsion systems*. John Wiley & Sons, 2011.
- [3] J. Van den Bergh, P. De Bruecker, J. Beliën, and J. Peeters, “Aircraft maintenance operations: state of the art,” *HUB Research Paper 2013/09*, 2013.
- [4] M. P. Boyce, *Gas turbine engineering handbook*. Elsevier, 2011.
- [5] M. Masiol and R. M. Harrison, “Aircraft engine exhaust emissions and other airport-related contributions to ambient air pollution: A review,” *Atmospheric Environment*, vol. 95, pp. 409–455, 2014.
- [6] R. Royce, *The jet engine*. John Wiley & Sons, 2015.
- [7] T. P. Carvalho, F. A. Soares, R. Vita, R. d. P. Francisco, J. P. Basto, and S. G. Alcalá, “A systematic literature review of machine learning methods applied to predictive maintenance,” *Computers & Industrial Engineering*, vol. 137, p. 106024, 2019.
- [8] R. K. Mobley, *An introduction to predictive maintenance*. Elsevier, 2002.
- [9] Y. Ran, X. Zhou, P. Lin, Y. Wen, and R. Deng, “A survey of predictive maintenance: Systems, purposes and approaches,” *arXiv preprint arXiv:1912.07383*, 2019.
- [10] N. Papakostas, P. Papachatzakis, V. Xanthakis, D. Mourtzis, and G. Chryssolouris, “An approach to operational aircraft maintenance planning,” *Decision support systems*, vol. 48, no. 4, pp. 604–612, 2010.
- [11] L. Swanson, “Linking maintenance strategies to performance,” *International journal of production economics*, vol. 70, no. 3, pp. 237–244, 2001.

- [12] L. Swanson, “Linking maintenance strategies to performance,” *International journal of production economics*, vol. 70, no. 3, pp. 237–244, 2001.
- [13] J. Wan, S. Tang, D. Li, S. Wang, C. Liu, H. Abbas, and A. V. Vasilakos, “A manufacturing big data solution for active preventive maintenance,” *IEEE Transactions on Industrial Informatics*, vol. 13, no. 4, pp. 2039–2047, 2017.
- [14] Z. Zhao, B. Liang, X. Wang, and W. Lu, “Remaining useful life prediction of aircraft engine based on degradation pattern learning,” *Reliability Engineering & System Safety*, vol. 164, pp. 74–83, 2017.
- [15] J. H. Williams, A. Davies, and P. R. Drake, *Condition-based maintenance and machine diagnostics*. Springer Science & Business Media, 1994.
- [16] P. P. Walsh and P. Fletcher, *Gas turbine performance*. John Wiley & Sons, 2004.
- [17] M. Paolanti, L. Romeo, A. Felicetti, A. Mancini, E. Frontoni, and J. Loncarski, “Machine learning approach for predictive maintenance in industry 4.0,” in *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA)*, pp. 1–6, IEEE, 2018.
- [18] S.-j. Wu, N. Gebraeel, M. A. Lawley, and Y. Yih, “A neural network integrated decision support system for condition-based optimal predictive maintenance policy,” *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, vol. 37, no. 2, pp. 226–236, 2007.
- [19] H. M. Hashemian, “State-of-the-art predictive maintenance techniques,” *IEEE Transactions on Instrumentation and measurement*, vol. 60, no. 1, pp. 226–236, 2010.
- [20] R. K. Mobley, *An introduction to predictive maintenance*. Elsevier, 2002.
- [21] A. S. . K. Goebel, “C-mapss data set.” NASA Ames Prognostics Data Repository, 2008.
- [22] A. Ahmadi, P. Söderholm, and U. Kumar, “On aircraft scheduled maintenance program development,” *Journal of Quality in Maintenance Engineering*, 2010.

- [23] K. N. Ali, M. Sun, G. Petley, and P. Barrett, “Improving the business process of reactive maintenance projects,” *Facilities*, 2002.
- [24] T. Zonta, C. A. Da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, and G. P. Li, “Predictive maintenance in the industry 4.0: A systematic literature review,” *Computers & Industrial Engineering*, vol. 150, p. 106889, 2020.
- [25] H. A. Gohel, H. Upadhyay, L. Lagos, K. Cooper, and A. Sanzetenea, “Predictive maintenance architecture development for nuclear infrastructure using machine learning,” *Nuclear Engineering and Technology*, vol. 52, no. 7, pp. 1436–1442, 2020.
- [26] Z. A. Bukhsh, A. Saeed, I. Stipanovic, and A. G. Doree, “Predictive maintenance using tree-based classification techniques: A case of railway switches,” *Transportation Research Part C: Emerging Technologies*, vol. 101, pp. 35–54, 2019.
- [27] R. S. Beebe and R. S. Beebe, *Predictive maintenance of pumps using condition monitoring*. Elsevier, 2004.
- [28] K. Khan, M. Sohaib, A. Rashid, S. Ali, H. Akbar, A. Basit, and T. Ahmad, “Recent trends and challenges in predictive maintenance of aircraft’s engine and hydraulic system,” *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 43, no. 8, pp. 1–17, 2021.
- [29] I. de Pater, A. Reijns, and M. Mitici, “Alarm-based predictive maintenance scheduling for aircraft engines with imperfect remaining useful life prognostics,” *Reliability Engineering & System Safety*, vol. 221, p. 108341, 2022.
- [30] C. Xiongzi, Y. Jinsong, T. Diyin, and W. Yingxun, “Remaining useful life prognostic estimation for aircraft subsystems or components: A review,” in *IEEE 2011 10th International Conference on Electronic Measurement & Instruments*, vol. 2, pp. 94–98, IEEE, 2011.
- [31] S. Vollert and A. Theissler, “Challenges of machine learning-based rul prognosis: A review on nasa’s c-mapss data set,” in *2021 26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, pp. 1–8, IEEE, 2021.

- [32] D. Rengasamy, H. P. Morvan, and G. P. Figueredo, “Deep learning approaches to aircraft maintenance, repair and overhaul: A review,” in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pp. 150–156, IEEE, 2018.
- [33] J.-H. Shin and H.-B. Jun, “On condition based maintenance policy,” *Journal of Computational Design and Engineering*, vol. 2, no. 2, pp. 119–127, 2015.
- [34] J. Kinghorst, O. Geramifard, M. Luo, H.-L. Chan, K. Yong, J. Folmer, M. Zou, and B. Vogel-Heuser, “Hidden markov model-based predictive maintenance in semiconductor manufacturing: A genetic algorithm approach,” in *2017 13th IEEE Conference on Automation Science and Engineering (CASE)*, pp. 1260–1267, IEEE, 2017.
- [35] D. Simon and S. Garg, “A systematic approach for model-based aircraft engine performance estimation,” in *AIAA Infotech@ Aerospace Conference and AIAA Unmanned... Unlimited Conference*, p. 1872, 2010.
- [36] J. R. Celaya, B. Saha, P. F. Wysocki, and K. F. Goebel, “Prognostics for electronics components of avionics systems,” 2009.
- [37] L. U. Gokdere, S. L. Chiu, K. J. Keller, and J. Vian, “Lifetime control of electro-mechanical actuators,” in *2005 IEEE Aerospace Conference*, pp. 3523–3531, IEEE, 2005.
- [38] P. Zhang and G. Chartrand, *Introduction to graph theory*. Tata McGraw-Hill, 2006.
- [39] M. Schwabacher, “A survey of data-driven prognostics,” *Infotech@ Aerospace*, p. 7002, 2005.
- [40] D. A. Tobon-Mejia, K. Medjaher, N. Zerhouni, and G. Tripot, “A data-driven failure prognostics method based on mixture of gaussians hidden markov models,” *IEEE Transactions on reliability*, vol. 61, no. 2, pp. 491–503, 2012.
- [41] V. Mathew, T. Toby, V. Singh, B. M. Rao, and M. G. Kumar, “Prediction of remaining useful lifetime (rul) of turbofan engine using machine learning,” in *2017*

- IEEE International Conference on Circuits and Systems (ICCS)*, pp. 306–311, IEEE, 2017.
- [42] P. Lim, C. K. Goh, and K. C. Tan, “A time window neural network based framework for remaining useful life estimation,” in *2016 international joint conference on neural networks (IJCNN)*, pp. 1746–1753, IEEE, 2016.
- [43] S. Patil, A. Patil, V. Handikherkar, S. Desai, V. M. Phalle, and F. S. Kazi, “Remaining useful life (rul) prediction of rolling element bearing using random forest and gradient boosting technique,” in *ASME international mechanical engineering congress and exposition*, vol. 52187, p. V013T05A019, American Society of Mechanical Engineers, 2018.
- [44] G. Sateesh Babu, P. Zhao, and X.-L. Li, “Deep convolutional neural network based regression approach for estimation of remaining useful life,” in *International conference on database systems for advanced applications*, pp. 214–228, Springer, 2016.
- [45] J. Wang, G. Wen, S. Yang, and Y. Liu, “Remaining useful life estimation in prognostics using deep bidirectional lstm neural network,” in *2018 Prognostics and System Health Management Conference (PHM-Chongqing)*, pp. 1037–1042, IEEE, 2018.
- [46] T. G. Dietterich, “Ensemble methods in machine learning,” in *International workshop on multiple classifier systems*, pp. 1–15, Springer, 2000.
- [47] X. Hu, Y. Che, X. Lin, and S. Onori, “Battery health prediction using fusion-based feature selection and machine learning,” *IEEE Transactions on Transportation Electrification*, vol. 7, no. 2, pp. 382–398, 2020.
- [48] K. Goebel and N. Eklund, “Prognostic fusion for uncertainty reduction,” in *Aiaa infotech@ aerospace 2007 conference and exhibit*, p. 2843, 2007.
- [49] E. Ramasso and A. Saxena, “Performance benchmarking and analysis of prognostic methods for cmaps datasets,” *International Journal of Prognostics and Health Management*, vol. 5, no. 2, pp. 1–15, 2014.

- [50] S. Badillo, B. Banfai, F. Birzele, I. I. Davydov, L. Hutchinson, T. Kam-Thong, J. Siebourg-Polster, B. Steiert, and J. D. Zhang, “An introduction to machine learning,” *Clinical pharmacology & therapeutics*, vol. 107, no. 4, pp. 871–885, 2020.
- [51] M. Arias Chao, C. Kulkarni, K. Goebel, and O. Fink, “Aircraft engine run-to-failure dataset under real flight conditions for prognostics and diagnostics,” *Data*, vol. 6, no. 1, p. 5, 2021.
- [52] J. Machin, D. Tucker, and J. Pearce, “A comprehensive survey of reported thermocouple drift rates since 1972,” *International Journal of Thermophysics*, vol. 42, no. 10, pp. 1–32, 2021.
- [53] B. Krose and P. v. d. Smagt, “An introduction to neural networks,” 2011.
- [54] C. Krittanawong, H. Zhang, Z. Wang, M. Aydar, and T. Kitai, “Artificial intelligence in precision cardiovascular medicine,” *Journal of the American College of Cardiology*, vol. 69, no. 21, pp. 2657–2664, 2017.
- [55] P. P. Shinde and S. Shah, “A review of machine learning and deep learning applications,” in *2018 Fourth international conference on computing communication control and automation (ICCUBEA)*, pp. 1–6, IEEE, 2018.
- [56] R. Caruana and A. Niculescu-Mizil, “An empirical comparison of supervised learning algorithms,” in *Proceedings of the 23rd international conference on Machine learning*, pp. 161–168, 2006.
- [57] P. Cunningham, M. Cord, and S. J. Delany, “Supervised learning,” in *Machine learning techniques for multimedia*, pp. 21–49, Springer, 2008.
- [58] Z. Ghahramani, “Unsupervised learning,” in *Summer school on machine learning*, pp. 72–112, Springer, 2003.
- [59] H. B. Barlow, “Unsupervised learning,” *Neural computation*, vol. 1, no. 3, pp. 295–311, 1989.
- [60] X. J. Zhu, “Semi-supervised learning literature survey,” 2005.

- [61] R. S. Sutton and A. G. Barto, *Reinforcement learning: An introduction*. MIT press, 2018.
- [62] M. A. Wiering and M. Van Otterlo, “Reinforcement learning,” *Adaptation, learning, and optimization*, vol. 12, no. 3, p. 729, 2012.
- [63] A. Burkov, *The hundred-page machine learning book*, vol. 1. Andriy Burkov Quebec City, QC, Canada, 2019.
- [64] M. Zinkevich, M. Weimer, L. Li, and A. Smola, “Parallelized stochastic gradient descent,” *Advances in neural information processing systems*, vol. 23, 2010.
- [65] A. Cutler, D. R. Cutler, and J. R. Stevens, “Random forests,” in *Ensemble machine learning*, pp. 157–175, Springer, 2012.
- [66] R. Genuer, J.-M. Poggi, C. Tuleau-Malot, and N. Villa-Vialaneix, “Random forests for big data,” *Big Data Research*, vol. 9, pp. 28–46, 2017.
- [67] R. Rojas, *Neural networks: a systematic introduction*. Springer Science & Business Media, 2013.
- [68] M. T. Hagan and H. B. Demuth, “Neural networks for control,” in *Proceedings of the 1999 American control conference (cat. No. 99CH36251)*, vol. 3, pp. 1642–1656, IEEE, 1999.
- [69] L. Jaw and J. Mattingly, *Aircraft engine controls*. American Institute of Aeronautics and Astronautics New York, NY, USA, 2009.
- [70] NASA, “C-mapss aircraft engine simulator data.” <https://data.nasa.gov/dataset/C-MAPSS-Aircraft-Engine-Simulator-Data/xaut-bemq>, 2022.
- [71] J. Marshall and M. Imregun, “A review of aeroelasticity methods with emphasis on turbomachinery applications,” *Journal of fluids and structures*, vol. 10, no. 3, pp. 237–267, 1996.
- [72] A. M. Limited, “What are hysteresis errors.” <https://appmeas.co.uk/resources/pressure-measurement-notes/what-are-hysteresis-errors/>, 2022.

- [73] U. of Cambridge, “Thermocouples: The operating principle.” <https://www.msm.cam.ac.uk/utc/thermocouple/pages/Drift.html>, 2022.
- [74] Y. Sommerer, V. Drouin, X. Nicolas, and B. Trouette, “Uncertainty quantification of thermocouple air temperature measurement in highly radiative environment: Application to turbofan engine compartment,” in *Turbo Expo: Power for Land, Sea, and Air*, vol. 49781, p. V05AT13A030, American Society of Mechanical Engineers, 2016.
- [75] U. of Cambridge, “Drift: A short explanation.” <https://www.msm.cam.ac.uk/utc/thermocouple/pages/Drift.html>, 2022.
- [76] C. Soares, *Gas turbines: a handbook of air, land and sea applications*. Elsevier, 2011.
- [77] A. Saxena, K. Goebel, D. Simon, and N. Eklund, “Damage propagation modeling for aircraft engine run-to-failure simulation,” in *2008 international conference on prognostics and health management*, pp. 1–9, IEEE, 2008.
- [78] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, and J. Lin, “Machinery health prognostics: A systematic review from data acquisition to rul prediction,” *Mechanical systems and signal processing*, vol. 104, pp. 799–834, 2018.
- [79] Q. Zhai and Z.-S. Ye, “Rul prediction of deteriorating products using an adaptive wiener process model,” *IEEE Transactions on Industrial Informatics*, vol. 13, no. 6, pp. 2911–2921, 2017.
- [80] F. O. Heimes, “Recurrent neural networks for remaining useful life estimation,” in *2008 international conference on prognostics and health management*, pp. 1–6, IEEE, 2008.
- [81] D. Singh and B. Singh, “Investigating the impact of data normalization on classification performance,” *Applied Soft Computing*, vol. 97, p. 105524, 2020.
- [82] H. Zhang, L. Zhang, and Y. Jiang, “Overfitting and underfitting analysis for deep learning based end-to-end communication systems,” in *2019 11th International*

- Conference on Wireless Communications and Signal Processing (WCSP)*, pp. 1–6, IEEE, 2019.
- [83] S. Flying, “The world’s most flown boeing 737s.” <https://simpleflying.com/the-worlds-most-flown-boeing-737s/>, 2021.
- [84] N. B. Gallagher, “Savitzky-golay smoothing and differentiation filter,” *Eigenvector Research Incorporated*, 2020.